

Trabajo final de grado

Obtención de mapas de humedad del combustible a partir de
variables meteorológicas para la predicción del riesgo de
incendios forestales a escala regional: nuevo enfoque a los
actuales índices de peligro de incendio

Autor: Àngel Cunill Camprubí
Tutor: Víctor Resco de Dios
Grado en Ingeniería Forestal
Universitat de Lleida

01 de octubre de 2018

OBTENCIÓN DE MAPAS DE HUMEDAD DEL COMBUSTIBLE A
PARTIR DE VARIABLES METEOROLÓGICAS PARA LA
PREDICCIÓN DEL RIESGO DE INCENDIOS FORESTALES A
ESCALA REGIONAL: NUEVO ENFOQUE A LOS ACTUALES
ÍNDICES DE PELIGRO DE INCENDIO

Trabajo final de grado

Àngel Cunill Camprubí

Tel.: 628 12 21 63

Correo electrónico: acumill86@gmail.com

Escola Tècnica Superior d'Enginyeria Agrària

Universitat de Lleida

2018

Índice de contenidos

Agradecimientos.....	xi
Resumen.....	xiii
1. Introducción	1
1.1. Problemática de los incendios forestales	1
1.2. Manejo de la problemática	1
1.3. Índices de riesgo o de peligro de incendio	2
1.4. Nuevo enfoque.....	3
1.5. Aplicación y uso de la información.....	4
2. Objetivos	7
3. Material y Métodos	9
3.1. Área de estudio	9
3.2. Predicción de la humedad del combustible	9
3.3. Datos	10
3.4. Filtrado de los datos	12
3.4.1. Valores perdidos.....	12
3.4.2. Coordenadas repetidas	12
3.4.3. Valores atípicos globales	12
3.5. Análisis estadístico exploratorio	12
3.5.1. Descripción de los datos.....	13
3.5.2. Distribución espacial de los puntos de muestreo.....	13
3.5.3. Representatividad de las elevaciones	14
3.5.4. Resumen	14
3.6. Análisis espacial: el variograma.....	15
3.6.1. Análisis visual de correlación espacial	16
3.6.2. Ajuste del modelo de semivarianza.....	17
3.6.3. Valores atípicos espaciales.....	18
3.7. Proceso de interpolación.....	18

3.7.1. Regresión lineal	18
3.7.2. Ponderación por el Inverso de la Distancia	20
3.7.3. Kriging Ordinario	21
3.8. Validación estadística de los métodos de interpolación.....	21
3.9. Definición de los umbrales críticos de humedad	23
3.10. Resumen del proceso de interpolación	25
4. Resultados y análisis	27
4.1. Análisis estadístico exploratorio	27
4.1.1. Descripción de los datos	27
4.1.2. Distribución espacial de los puntos de muestreo	28
4.1.3. Representatividad de las elevaciones.....	29
4.2. Análisis espacial.....	30
4.2.1. Análisis visual	30
4.2.2. Ajuste del modelo de semivarianza	31
4.2.3. Valores atípicos	34
4.3. Métodos de interpolación	35
4.3.1. Regresión lineal	35
4.3.2. Validación y comparación de los métodos.....	37
4.4. Mapas.....	41
4.4.1. Interpolaciones y humedad de los combustibles	41
4.4.2. Mapas de disponibilidad de los combustibles	45
5. Discusión de los resultados.....	47
5.1. Análisis preliminar de los datos	47
5.2. Relaciones espaciales.....	48
5.2.1. Autocorrelación, estacionariedad e isotropía	48
5.2.2. Modelización de la variación espacial.....	49
5.2.3. Valores atípicos espaciales	49
5.3. Rendimiento de los métodos de interpolación.....	50
6. Aplicación funcional.....	53
6.1. Aplicación y uso de los mapas	53
6.2. Operatividad y necesidad de la aplicación.....	54
6.3. Dificultades y soluciones previstas	55

7. Conclusiones.....	57
8. Referencias	59

Contenido complementario del CD

- Anexo 1. Resultados de los modelos de regresión lineal
- Anexo 2. Variogramas experimentales
- Anexo 3. Parámetros y gráficos de los variogramas teóricos
- Anexo 4. Resultados de la validación de las interpolaciones
- Aplicativo en código R para el procedimiento de obtención de los mapas de humedad
- Datos meteorológicos brutos
- Resultados brutos de los análisis

Índice de tablas y figuras

Tablas

Tabla 1. Definición de los umbrales críticos de humedad de los combustibles finos muertos (FM) según Boer et al. (2017). Relación entre las categorías de disponibilidad de los combustibles finos muertos, los valores críticos de FM y su representación colorimétrica.	24
Tabla 2. Estadísticos descriptivos de los datos observados para la temperatura máxima diaria y la temperatura en el punto de rocío. Valores promedio de los meses de junio, julio y totales.	27
Tabla 3. Tipos de ajuste de los variogramas teóricos para la temperatura máxima ($T_{máx}$) y la temperatura en el punto de rocío (T_{pr}).	32
Tabla 4. Resumen de los parámetros de los variogramas teóricos para la temperatura máxima ($T_{máx}$) y la temperatura en el punto de rocío (T_{pr}).	32
Tabla 5. Error absoluto medio (MAE), raíz del error cuadrático medio (RMSE), error medio (MBE) y coeficiente de determinación (R^2) de los distintos métodos de interpolación. Valores promedio para la temperatura máxima ($T_{máx}$) y la temperatura en el punto de rocío (T_{pr}) en el periodo de estudio.	38
Tabla 6. Estimaciones del error absoluto medio (MAE) para el déficit de presión de vapor (D) y la humedad de los combustibles finos muertos (FM).	40

Figuras

Figura 1. Distribución de las estaciones meteorológicas en el área de estudio.	11
Figura 2. Diagrama de progresión del análisis estadístico exploratorio. Pasos, tipo de análisis y métodos o medidas.	14
Figura 3. Ejemplo de semivariograma. γ_h , semivarianza, h , distancia, C_0 , covarianza mínima; C_0+C_L , covarianza máxima (Tomado de Hengl, 2009).	16
Figura 4. Relación entre el área acumulada quemada por los incendios forestales en Portugal (2001-2015) y el contenido de humedad de los combustibles finos muertos (FM) estimado. Las	

barras grises verticales representan el intervalo de confianza del 95% de los umbrales críticos de humedad del combustible. Extraído de Boer et al. (2017).23

Figura 5. Diagrama resumen del proceso metodológico. [...] indica que se repiten los pasos que engloba el recuadro numerado con la línea discontinua. (*) cada método de interpolación combina sus propios mapas de temperatura máxima ($T_{m\acute{a}x}$) y temperatura en el punto de rocío (T_{pr}).25

Figura 6. Ejemplos de histogramas de densidad y diagramas de caja representativos de las variables temperatura máxima ($T_{m\acute{a}x}$; izquierda) y temperatura en el punto de rocío (T_{pr} ; derecha). Histograma: la línea continua indica la función de distribución de la variable; la línea discontinua hace referencia a una distribución normal con media y desviación estándar igual a las de la distribución observada.28

Figura 7. Contraste de Aleatoriedad Espacial Completa (CRS) y la distribución de puntos observada (A, *función G*; B, *función F*) para un número promedio de puntos de muestreo válidos, con los límites del intervalo de confianza del 96% sobre 100 simulaciones de CRS. *obs*, distribución observada; *teo*, distribución teórica; *int*, intervalo de confianza.29

Figura 8. A. Histograma comparativo de la altitud de los puntos de muestreo (estaciones meteorológicas) y las elevaciones del área de estudio extraídas del modelo digital del terreno. B. Correspondencia entre las elevaciones de las estaciones AEMET y las elevaciones obtenidas del MDE en las mismas localizaciones. La línea discontinua roja indica la relación 1:1; la línea continua negra es la recta de la regresión.30

Figura 9. Parámetros de los variogramas teóricos obtenidos para la temperatura máxima ($T_{m\acute{a}x}$) y para la temperatura en el punto de rocío (T_{pr}) en el periodo de estudio. La línea discontinua roja indica la media aritmética; la línea discontinua gris representa la mediana aritmética...32

Figura 10. Ejemplos de variogramas teóricos de la temperatura máxima ($T_{m\acute{a}x}$; A) y la temperatura en el punto de rocío (T_{pr} ; B, C y D). γh , semivarianza; h , distancia.33

Figura 11. Ejemplo de localización de valores espaciales discordantes de temperatura máxima ($T_{m\acute{a}x}$) y los variogramas teóricos correspondientes ajustados con y sin estos valores. MAE, error absoluto medio obtenido de una validación cruzada con el método de *kriging* ordinario.34

Figura 12. Ejemplo de localización de valores espaciales discordantes de temperatura en el punto de rocío (T_{pr}) y los variogramas teóricos correspondientes ajustados con y sin estos valores. MAE, error absoluto medio obtenido de una validación cruzada con el método de *kriging* ordinario.35

Figura 13. Valores del coeficiente de correlación de Pearson entre la temperatura máxima ($T_{m\acute{a}x}$) y las variables auxiliares *elevación* (A), *latitud* (B) y *longitud* (C). La línea roja marca el valor

promedio obtenido en el periodo de estudio. Los puntos por encima de la línea de unión de los valores (línea negra) indican que no son estadísticamente distintos de 0, con un nivel de confianza del 95%..... 36

Figura 14. Valores del coeficiente de correlación de Pearson entre la temperatura del punto de rocío (T_{pr}) y las variables auxiliares *elevación* (A), *latitud* (B) y *longitud* (C). La línea roja marca el valor promedio obtenido en el periodo de estudio. Los puntos por encima de la línea de unión de los valores (línea negra) indican que no son estadísticamente distintos de 0, con un nivel de confianza del 95%..... 37

Figura 15. Valores diarios del error absoluto medio (MAE), raíz del error cuadrático medio (RMSE) y coeficiente de determinación (R^2) calculados a partir de las estimaciones de la temperatura máxima ($T_{máx}$) realizadas con los distintos métodos de interpolación. 39

Figura 16. Valores diarios del error absoluto medio (MAE), raíz del error cuadrático medio (RMSE) y coeficiente de determinación (R^2) calculados a partir de las estimaciones de temperatura del punto de rocío (T_{pr}) realizadas con los distintos métodos de interpolación.. 39

Figura 17. Ejemplo de relaciones entre el déficit de presión de vapor (D), la humedad de los combustibles finos muertos (FM), la humedad relativa mínima (HR), la temperatura máxima ($T_{máx}$) y la temperatura en el punto de rocío (T_{pr}). 41

Figura 18. Mapas de temperatura máxima ($T_{máx}$) del día 25 de julio de 2018. El mapa superior muestra los valores observados; el resto son los mapas interpolados con regresión lineal 1 (RL1), regresión lineal 2 (RL2), ponderación por el inverso de la distancia (IDW) y *kriging* ordinario (OK). 42

Figura 19. Mapas de temperatura del punto de rocío (T_{pr}) del día 25 de julio de 2018. El mapa superior muestra los valores observados; el resto son los mapas interpolados con regresión lineal 1 (RL1), regresión lineal 2 (RL2), ponderación por el inverso de la distancia (IDW) y *kriging* ordinario (OK). 43

Figura 20. Mapas de déficit de presión de vapor (D ; izquierda) y humedad de los combustibles finos muertos (FM ; derecha) del día 25 de julio de 2018. RL1, regresión lineal 1; RL2, regresión lineal 2; IDW, ponderación por el inverso de la distancia; OK, *kriging* ordinario. 44

Figura 21. Mapas de humedad y de disponibilidad de los combustibles finos muertos de días aleatorios en el periodo del 3 al 8 de septiembre. 45

Agradecimientos

Primero de todo, quiero dar las gracias a mi tutor, Víctor Resco de Dios, por haberme planteado este reto que hoy concluyo y por haber confiado en mí ciegamente desde un principio.

También agradezco enormemente la ayuda desinteresada de Matthias M. Boer, de la Universidad de Western Sydney, quien nos dio consejos y nos mostró las pautas iniciales para que pudiera empezar y realizar este trabajo.

A mi pareja, Marta, por sus aportes en la revisión del texto y las ayudas en situaciones de bloqueo. Gracias por tener tanta paciencia y por tu apoyo incondicional en todo momento.

Por supuesto, a mis padres, y a todos aquellos que han contribuido de alguna manera a que esto fuera posible.

A todos vosotros, muchísimas gracias.

Resumen

Los incendios forestales constituyen una de las mayores perturbaciones ecológicas a nivel mundial y, en especial, en las regiones mediterráneas. Los ciclos de recurrencia cada vez más cortos por causas como el calentamiento global, y el aumento de la carga de combustible en los montes tras el éxodo rural y la presión de extinción de las últimas décadas, suponen un riesgo creciente importante para la población que habita el territorio.

Para anticiparse a situaciones de peligro y permitir la movilización de recursos, este trabajo propone la aplicación espacial de un índice meteorológico de riesgo de incendios forestales definido por el contenido mínimo de humedad de los combustibles finos muertos (FM) y la relación existente con el área quemada tras un incendio. La idea surge tras examinar las carencias de los actuales índices de peligro de incendio en predecir, con cierta exactitud, el lugar y el momento de la ocurrencia de un incendio forestal.

El modelo empleado para predecir FM se basa en la relación entre el contenido de humedad y el déficit de presión de vapor (D). En este caso, D fue calculado a través de los registros de temperatura máxima y humedad relativa mínima obtenidos del servicio meteorológico del país y extendidos a todo el territorio.

Con este fin, se probaron las tres técnicas de interpolación más comparadas en la literatura: la regresión lineal (RL), la ponderación por el inverso de la distancia (IDW) y el *kriging* ordinario (OK). Dentro de la RL se evaluaron dos funciones diferentes (RL1 y RL2) con la elevación, la latitud y la longitud como variables de entrada.

El estudio se realizó en el territorio español de la Península Ibérica y las Islas Baleares, y durante los meses de junio y julio de 2018. Antes de aplicar los métodos se realizó un análisis profundo de la naturaleza de los datos, de la representatividad del área de estudio y de las relaciones espaciales de las variables de interés.

Los análisis desvelaron la existencia de tendencias a gran escala incompatibles con el uso de IDW y OK. Para solucionarlo, se aplicó un enfoque localizado a estos métodos con el cual se reducía el número de puntos de influencia en las predicciones a un radio de búsqueda específico de 250 km.

En términos de error y efectividad, los resultados más favorables se obtuvieron con la técnica de OK. Los mapas generados presentaron una continuidad suave y coherente con los sucesos registrados. Aunque el peor rendimiento fue para los modelos lineales, estos pueden servir de apoyo en métodos combinados de *kriging* para modelizar las tendencias a gran escala y mejorar aún más el rendimiento del método aquí propuesto para predecir el riesgo de incendio.

Este trabajo sirve de base para la creación de una aplicación automatizada de predicción de humedad del combustible fino muerto, con la consecuente probabilidad de incendio asociada. Esta aplicación busca ser operativa entre los cuerpos de extinción de incendios forestales para poder establecer un sistema de alerta temprana cuando las condiciones meteorológicas sean favorables a los grandes incendios forestales y poder así, disminuir los costes asociados a la movilización de medios.

1. Introducción

1.1. Problemática de los incendios forestales

Los incendios forestales son un fenómeno recurrente de los paisajes forestales a nivel global (Boer et al., 2017). En las regiones mediterráneas, los incendios forestales son un elemento natural de los ecosistemas que se ve favorecido por la estacionalidad del clima mediterráneo (Pausas y Vallejo, 2008; Vélez, 1995).

A pesar de ello, los recientes cambios en el paisaje tras el abandono rural producido en Europa en la última mitad de siglo, las repoblaciones forestales para evitar las pérdidas de suelo, y una política de extinción de incendios imperante frente a la gestión de los montes, han derivado en un incremento y una mayor continuidad de la superficie forestal que ha provocado la alteración de los regímenes de incendios en muchos lugares del mundo (Castellnou, Miralles, y Molina, 2005; Pausas y Fernández-Muñoz, 2012).

A este aumento de la superficie forestal y de su continuidad se le añade el incremento en la evapotranspiración y la intensidad de las sequías estivales debido al cambio climático, que se traduce en un aumento de la inflamabilidad de nuestros montes (Pausas, 2004; Pausas y Fernández-Muñoz, 2012).

Todo ello supone un impacto creciente con consecuencias económicas y ecológicas a veces irreversibles (Chuvieso y Martín, 2004) al cual, si añadimos el urbanismo caótico y salvaje de los últimos años donde la frontera entre lo urbano y lo forestal se difumina, hace que los incendios del siglo XXI dejen de ser un problema estrictamente ambiental para pasar a ser una emergencia civil (Hernández, 2017).

1.2. Manejo de la problemática

Cuando se origina un incendio en zonas con cargas de combustible muy altas y en días con condiciones meteorológicas adversas, el comportamiento del fuego puede ser tan extremo que no exista ninguna posibilidad para que los medios de extinción puedan controlarlo (Hernández, 2017). Estamos hablando de Grandes Incendios Forestales (GIF); incendios que se propagan a una velocidad e intensidad que superan la capacidad de extinción de los medios (Castellnou et al., 2005).

Para reducir los efectos negativos causados por este fenómeno es necesario contar con un sistema de prevención de incendios capaz de predecir con cierta exactitud y precisión dónde y cuándo se puede desarrollar un incendio de estas condiciones (Chuvieso y Martín, 2004).

Una de las políticas comunes del conjunto de países en los que el fuego juega un papel fundamental (Europa mediterránea, EUA, Australia, etc.) es la distribución de los recursos de extinción según la predicción del riesgo de incendio (Castellnou, Pagés, Miralles, y Piqué, 2009). El análisis de este factor mediante índices representativos permite optimizar la gestión de dichos recursos y anticiparse estratégicamente a la aparición del problema, concentrándolos en una zona en el momento en que sea posible la ocurrencia de un GIF (Castellnou et al., 2005; Generalitat de Catalunya, 2009).

1.3. Índices de riesgo o de peligro de incendio

La definición de riesgo de incendio más comúnmente adoptada por las organizaciones internacionales dice que ‘*el riesgo de incendio es la posibilidad de que se inicie un incendio, según se vea afectado por la naturaleza y la incidencia de los agentes causantes*’, sin entrar en valores o en la estimación de posibles daños (Hardy, 2005).

La probabilidad de ignición y de propagación de un fuego está inversamente relacionada con el contenido de humedad de los combustibles (Aguado y Camia, 1998; Nelson, 2001). Esto es porque parte de la energía necesaria para iniciar un incendio se utiliza en el proceso de evaporación justo antes de que el fuego comience a arder (Scott, Bowman, Bond, Pyne, y Alexander, 2014).

Si diferenciamos entre combustibles vivos y combustibles muertos, los cambios en la humedad de los primeros ocurren más lentamente que en los combustibles muertos debido a que dependen, en gran medida, del contenido de humedad del suelo (Nolan, Boer, Resco De Dios, Caccamo, y Bradstock, 2016).

Atendiendo a este hecho y a que los combustibles finos arden antes que los más gruesos (Scott et al., 2014; Vélez, 1995), un factor importante en la determinación del riesgo de incendio sería el contenido de humedad de los combustibles finos muertos (*FM*), considerando como tal los restos de tallos y ramillas con un diámetro inferior a 25,4 mm (Scott et al., 2014).

En este caso, su estado de humedad responde a los cambios en las condiciones atmosféricas a través de la adsorción y desorción de vapor de agua (Aguado, Chuvieco, Borén, y Nieto, 2007; Nolan, Resco de Dios, et al., 2016) y actúa como un “interruptor” que se activa o desactiva para que se inicie un fuego o no (Bradstock, 2010; Ruiz González y Vega Hidalgo, 2007).

Los índices meteorológicos de peligro de incendio, como el Canadian Forest Fire Weather Index (FWI) o el McArthur Forest Fire Danger Index (FFDI) son utilizados comúnmente y de manera extensiva para estimar el contenido de humedad del combustible y, con ello, la probabilidad de que se produzca una ignición (Aguado et al. 2007; Boer et al., 2017).

A nivel Europeo, los mapas meteorológicos diarios de peligro de incendios que publica la Comisión Europea, a través del llamado European Forest Fire Information System (EFFIS) (European Commission, 2018) se obtienen a partir de los índices del sistema canadiense (FWI).

En España, el nivel de riesgo meteorológico diario de incendios forestales está basado en este mismo sistema y se calcula a partir de los datos de las estaciones meteorológicas de la Agencia Estatal de Meteorología (AEMET) y de las salidas de un modelo numérico de predicción del tiempo (AEMET, 2018b). Más concretamente, en Cataluña se publica diariamente el mapa de riesgo diario de incendios (DARPA, 2018) usando el FWI y la red de estaciones meteorológicas automáticas del Servicio Meteorológico de Cataluña (Burriel et al., 2006).

1.4. Nuevo enfoque

Los índices de sequía empleados en los actuales índices de peligro de incendios tienden a tener capacidades limitadas para pronosticar en qué momento los combustibles están disponibles para arder (Aguado et al., 2007; Boer et al., 2017; Castellnou et al., 2005; Martin Soler et al., 2017). Su uso se ha extendido a países o regiones cuyas condiciones ambientales son muy diferentes a aquellas en las que se desarrolló el sistema (Aguado et al., 2007; Chuvieso, 2003).

Al mismo tiempo se ha demostrado que los mayores incendios ocurren fuera del periodo más seco (Chuvieso y Martín, 2004), como el ocurrido en Pedrogão Grande (Portugal) en 2017, donde la situación crítica tuvo lugar a principios de junio y el índice FWI no proporcionó una advertencia temprana sobre el extremo peligro de incendio experimentado durante los días de los incendios (Boer et al., 2017).

Recientemente, Resco de Dios et al. (2015) han desarrollado un modelo semi-mecanicista para predecir la humedad de los combustibles finos muertos basado en el intercambio de vapor de agua entre la atmósfera y los tejidos higroscópicos de los combustibles muertos, que proporciona resultados más exactos y precisos en una amplia variedad de lugares y ecosistemas en comparación con 8 modelos distintos, incluidos los usados en los principales índices de peligro de incendios.

Por otra parte, la relación encontrada entre el contenido de humedad de dichos combustibles y el área quemada por un incendio ha permitido determinar unos niveles críticos de humedad, aplicables a una gran amplia variedad de latitudes y tipos de vegetación, cuyo exceso conduce a la ocurrencia de mayores incendios forestales (Nolan, Boer, et al., 2016).

Es importante matizar que estos cambios en la humedad de los combustibles asociados con el incremento brusco de grandes áreas quemadas ocurren a macro-escala en un lapso relativamente corto (días) para los combustibles finos muertos (Boer et al., 2017; Nolan, Boer, et al., 2016), con lo cual pueden ser considerados como la primera condición necesaria o interruptor que debe ser activado para que ocurra un incendio (Nolan, Boer, et al., 2016).

Por este motivo, la predicción del contenido de humedad de los combustibles finos muertos puede suponer un aviso anticipado de cambios en la disponibilidad de los montes (Boer et al., 2017) y ser de gran ayuda a la administración forestal para la toma de decisiones en la movilización de personal, la asignación de recursos y la restricción de actividades en el entorno natural (Resco de Dios et al., 2015).

1.5. Aplicación y uso de la información

El principal objetivo de este trabajo es dar forma a un índice de riesgo de incendio basado en los umbrales críticos de humedad de los combustibles finos muertos definidos por Nolan, Boer, et al. (2016), cuyo valor se consigue estimar a partir del modelo semi-mecanicista desarrollado por Resco de Dios et al. (2015) y aplicar a nivel regional a la Península Ibérica y Baleares siguiendo la metodología de Nolan, Resco de Dios, et al. (2016).

Dicho modelo precisa de datos meteorológicos como variables de entrada que se pueden adquirir regularmente de las estaciones meteorológicas y que deben ser “espacializados” mediante técnicas de interpolación espacial.

En términos generales, un método de interpolación es una herramienta que permite el cálculo del valor de una variable primaria en puntos desconocidos dentro de la misma región donde se han obtenido ubicaciones con valores conocidos (Olaya, 2014), pudiendo generar superficies continuas para todo el área de interés.

Existe un gran número de métodos de interpolación espacial que pueden clasificarse de varias maneras (Li y Heap, 2008, 2011, 2014). Li y Heap (2014) proponen una clasificación en tres grupos: los métodos no-geoestadísticos, los métodos geoestadísticos y los métodos combinados.

La geoestadística es un conjunto de técnicas y estimadores, basados en la teoría de la probabilidad, que utilizan la variabilidad espacial y la correlación de un fenómeno distribuido de manera continua en el espacio para predecir valores en lugares no muestreados (Benavides, Montes, Rubio y Osoro, 2007). Por el contrario, los métodos no-geoestadísticos normalmente son métodos determinísticos cuyos modelos emplean parámetros empíricos o arbitrarios sin la necesidad de conocer la relación espacial de la variable de interés.

En general, el fundamento de los métodos de interpolación es una aplicación directa de la *ley de Tobler*, que establece que los puntos cercanos tienen mayor probabilidad de tener valores similares que aquellos separados por una distancia mayor (Miller, 2004).

Una visión más profunda sobre los conceptos básicos y las asunciones de los principales métodos de interpolación espacial se puede leer en Cressie (1993), Li y Heap (2008) y Webster y Oliver (2007).

Este trabajo supone una primera aproximación al conocimiento y aplicación de los métodos de interpolación espacial como herramienta para generar los mapas de humedad. De entre el gran número de técnicas usadas en la interpolación de variables meteorológicas (Li y Heap, 2011), aquí se escogieron 3 de las más utilizadas: la regresión lineal (RL), el método de ponderación por el inverso de la distancia (IDW, *inverse distance weighting* en inglés) y el método geoestadístico de *kriging* ordinario (OK, *ordinary kriging* en inglés), para evaluar su eficacia y aplicabilidad en la generación de mapas de humedad del combustible en España.

Una vez obtenidos los mapas de humedad a escala regional, el siguiente paso fue definir un índice categórico adaptado a los niveles críticos de humedad del territorio, con la intención de,

en un futuro próximo, ser publicado en internet diariamente para su uso general por los organismos de control, prevención y extinción de incendios como complemento o substitución de los actuales índices de peligro de incendios.

2. Objetivos

El objetivo principal de este trabajo es:

- Generar mapas de humedad de los combustibles finos muertos creados a partir de datos meteorológicos diarios descargados automáticamente.

Los objetivos específicos son:

- Comparar el rendimiento de diferentes técnicas de interpolación de las variables meteorológicas.
- Elaborar un aplicativo informático que permita automatizar el proceso de interpolación con el método que mejor se adapte a ello y teniendo en cuenta todos los parámetros posibles que se deban considerar.

3. Material y Métodos

3.1. Área de estudio

El área de estudio se centró en España peninsular e Islas Baleares, que en conjunto cubren una superficie de 502 494 km² localizada entre los 36,00° y 43,79° de latitud y los -9,30° y 4,33° de longitud.

Esta parte de Europa se divide en dos biomas (Olson et al., 2001): el bioma de los bosques templados de hoja ancha y mixtos, y el bioma de los bosques y matorrales mediterráneos. El primero de ellos se extiende por la zona norte de la península, desde el límite con Portugal hasta los Pirineos, y engloba los tipos de clima templados húmedos (oceánico y mediterráneo húmedo) según la clasificación de Köppen-Geiger (AEMET-IM, 2011). El segundo bioma conforma el resto del territorio, con climas de tipo mediterráneo seco y caluroso en verano. Localmente, también existen zonas de montaña con climas fríos restringidas en áreas del Pirineo, Cordillera Cantábrica, Sistema Ibérico, Sistema Central y Sierra Nevada.

3.2. Predicción de la humedad del combustible

La humedad de los combustibles finos muertos (<25,4 mm) se estimó a partir del déficit de presión de vapor (D) con el modelo desarrollado por (Resco de Dios et al., 2015) y calibrado por (Nolan, Resco de Dios, et al., 2016):

$$FM_D(\%) = 6,79 + 27,43e^{(-1,05 D)} \quad (1)$$

donde D se obtiene del cálculo de la presión de saturación del vapor de agua (e_s) y la presión real de vapor de agua (e_a), en función de la temperatura del aire (T_{air}) y la humedad relativa (HR). Para ello, se utilizó el conjunto de ecuaciones de la librería `plantecophys` (Duursma, 2015) dentro del paquete ofimático R (R Core Team, 2018) con el cual se llevó a cabo todo el proceso:

$$e_s(kPa) = 0,6138 \cdot \exp\left(17,502 \cdot \frac{T_{air}}{T_{air} + 240,97}\right) \quad (2)$$

$$e_a(kPa) = \frac{HR}{100} \cdot e_s \quad (3)$$

$$D(kPa) = e_s - e_a \quad (4)$$

Las unidades para la T_{air} y la HR se debían introducir en grados Celsius ($^{\circ}\text{C}$) y tanto por ciento (%), respectivamente.

Para determinar el contenido mínimo diario de humedad de los combustibles finos muertos, D se estimó a partir del valor máximo de la temperatura media del aire ($T_{m\acute{a}x}$) registrada en las últimas 24 horas, y el valor de HR en el momento de $T_{m\acute{a}x}$.

Debido a que la HR depende tanto de la T_{air} como de su contenido de humedad (Monteith y Unsworth, 2013; Wallace y Hobbs, 2006) y a que la T_{air} guarda buena relación con la altitud, la latitud y otras variables topográficas (Cáceres, Martín, Granda y Cabon, 2018), la HR se convirtió a la temperatura del punto de rocío (T_{pr})¹ antes de la interpolación, con el fin de poder aplicar los modelos de regresión lineal propuestos en el apartado 3.7.1.

Para obtener la T_{pr} , se necesitó calcular primero la e_a mediante las Ecs. 2 y 3. Luego, la T_{pr} se dedujo de la siguiente expresión:

$$T_{pr}(^{\circ}\text{C}) = \frac{240,97 \cdot \ln(e_a/0,6138)}{17,502 - \ln(e_a/0,6138)} \quad (5)$$

Dado que conocemos e_a y e_s , el proceso inverso nos permite volver a los valores de HR una vez hecha la interpolación del mapa de la T_{pr} .

3.3. Datos

Los datos meteorológicos requeridos para el cálculo del déficit de presión de vapor (D) se obtuvieron del servicio de uso público de consulta ‘AEMET OpenData’ de la Agencia Estatal de Meteorología (AEMET, 2018a). Este servicio funciona mediante el uso de una clave API (Application Programming Interface) que permite la comunicación entre el proveedor, en este caso AEMET, y nuestro software propio para adquirir la información de forma automática.

El programa utilizado para descargar los datos de forma automática fue la función `downloadAEMETcurrentday` de la librería `meteoland` (Cáceres et al., 2018). Esta función nos permite descargar las observaciones horarias de las últimas 24 horas de todas las estaciones meteorológicas del Estado Español de las que se han recibido registros en ese período, con una frecuencia de actualización continua. La distribución geográfica de estos puntos de muestreo en el área de estudio se puede ver en la Figura 1.

El resultado de la descarga es un objeto espacial (clase `SpatialPointsDataFrame`; Pebesma y Bivand, 2005) que contiene los valores de altitud, temperatura media, temperatura mínima, temperatura máxima, precipitación, velocidad del viento, dirección del viento, humedad

¹La temperatura del punto de rocío (T_{pr}) de una porción de aire con presión de vapor e_a es la temperatura a la que debe enfriarse este para saturarse, es decir, cumple con $e_a = e_s(T_{pr})$.

relativa media, humedad relativa mínima y humedad relativa máxima de cada estación en forma de tabla, con su código identificador y sus coordenadas geográficas.

Para el análisis y los ajustes de la interpolación se usó el registro diario de datos meteorológicos en el periodo comprendido entre el 1 de junio y el 31 de julio de 2018.

El Modelo Digital de Elevaciones (MDE) de España (IGN, 2018), descargado con un tamaño de celda de 200 m x 200 m, se empleó como representación del área de estudio y como base para las predicciones. Por motivos computacionales y con el fin de agilizar los procesos de análisis previos, el MDE se escaló a una resolución de 1000 m mediante interpolación bilineal con el programa informático ArcGIS. Más adelante, la determinación final de la precisión de los mapas interpolados se hizo en base al criterio de la densidad promedio de puntos en el área de estudio descrito por Hengl (2006) y acorde con un tamaño aceptable del archivo final generado, en términos de espacio en la memoria de la computadora.

Como sistema de referencia de los mapas y de los datos se utilizó el European Terrestrial Reference System de 1989 (ETRS89) con proyección UTM (Universal Transverse Mercator) en el huso 30.

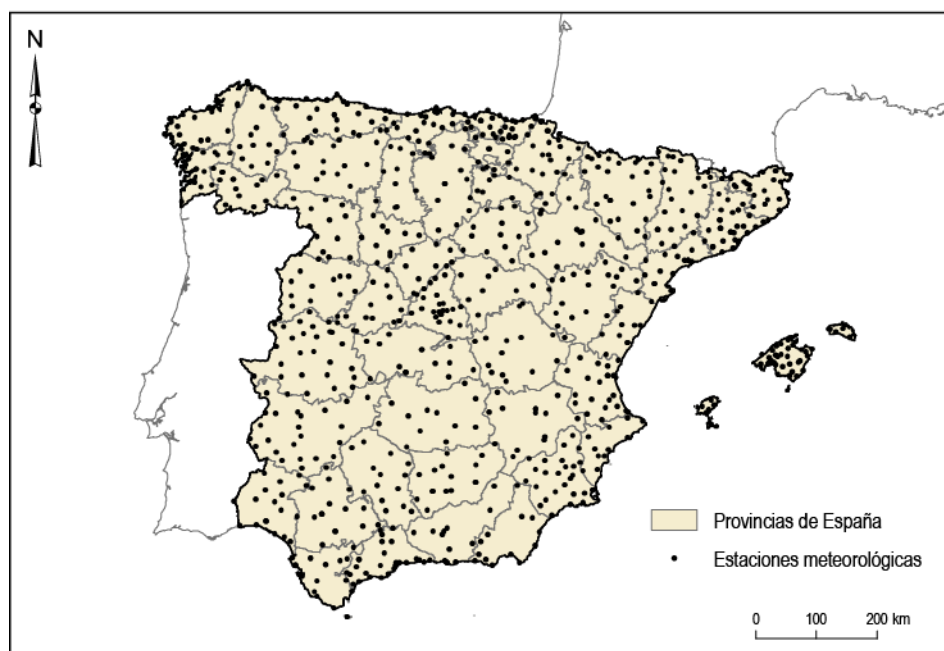


Figura 1. Distribución de las estaciones meteorológicas en el área de estudio.

3.4. Filtrado de los datos

Antes de proceder con los análisis estadísticos de las variables fue preciso preparar el conjunto de datos para evitar errores en su caracterización o efectos indeseados en el proceso de interpolación. En los siguientes puntos se explica cómo se trataron los valores perdidos, los puntos con coordenadas repetidas y los valores atípicos globales del conjunto de datos.

3.4.1. Valores perdidos

Los valores perdidos son datos sin registro de una o varias variables de las observaciones que conforman la información descargada. Dada la necesidad de tener valores de los atributos espaciales en cada punto registrado se eliminaron, independientemente para cada variable, aquellas estaciones con un dato faltante de la variable de interés (también llamada variable objetivo).

3.4.2. Coordenadas repetidas

En la exploración diaria de los datos se observó que, en ocasiones, existían dos registros en un mismo punto del espacio con atributos no coincidentes. Su detección fue sencilla, sin embargo, el proceso de automatización complicaba la elección de cuál de los dos puntos debe eliminarse. Como norma subjetiva, se decidió eliminar el valor con un registro menor de temperatura máxima para evitar una subestimación en la interpolación de D en ese punto. Con ello también se elimina el valor más alto de HR de entre los dos posibles.

3.4.3. Valores atípicos globales

Un valor atípico (*outlier*, en inglés) es una observación dentro de un conjunto de datos que no parece guardar consistencia con el resto del conjunto. Tomando como referencia a (Gaona, Quentin, y Labus, 2013), se estableció que los valores fuera del límite de 5 desviaciones estándar con respecto a la media de la distribución de la variable eran *valores atípicos globales*, y se extrajeron de las observaciones. El complemento *global* indica que solamente hacen referencia a la componente temática o atributo del conjunto de datos, sin inferir en su relación espacial (los valores atípicos con dependencia espacial se tratan más adelante en el apartado 3.6.3).

Adicionalmente, para interpolar la T_{pr} y previo a su conversión a partir de la HR , se comprobó que los valores de esta última se encontraban dentro del intervalo $[0, 100]$.

3.5. Análisis estadístico exploratorio

El rendimiento de los métodos de interpolación espacial depende de las suposiciones y las propiedades que deben cumplirse para cada uno de ellos (Olaya, 2014). Un análisis estadístico exploratorio previo es necesario para conocer ciertas características de los datos que ayudan a aplicar correctamente las técnicas (normalidad de los datos, media constante, etc.) y a prescindir de algunos métodos inapropiados (Li y Heap, 2014).

Una descripción detallada de los factores que afectan al funcionamiento de los métodos de interpolación se puede leer en las publicaciones de Li y Heap (2008, 2014).

Para este trabajo, el análisis estadístico exploratorio que se llevó a cabo residió en evaluar la consistencia y la naturaleza de los datos de entrada por medio de técnicas descriptivas de la estadística clásica, y en detectar problemas de representatividad del área de estudio a través del estudio de la distribución espacial de los puntos de muestreo y el análisis de la distribución de elevaciones.

3.5.1. Descripción de los datos

El proceso descriptivo se hizo siguiendo la metodología definida por Webster y Oliver (2007) y el ejemplo desarrollado por Miranda-Salas y Condal (2003). Se realizó el análisis gráfico de la distribución y se calcularon medidas de amplitud, de tendencia central, de dispersión y de estructura de las variables de interés, con la intención de detectar tendencias o distintas poblaciones en la región e identificar valores improbables de la muestra. De forma anexa, se empleó la prueba de Kolmogorov-Smirnov con corrección de Lillieforts para certificar estadísticamente la normalidad de las distribuciones de ambas variables.

3.5.2. Distribución espacial de los puntos de muestreo

La distribución espacial de la red de estaciones meteorológicas (puntos de muestreo o eventos) se estudió mediante el *Análisis de Patrones de Puntos*. Este tipo de análisis sirvió para definir la cantidad de puntos y su disposición sobre el área de estudio, independientemente de sus atributos. Para ello, se estimaron los parámetros de intensidad (densidad promedio de puntos), distancias entre puntos y su configuración en el espacio, mediante el uso de las funciones `mdist` y `envelope` de la librería `spatstat` de R (Baddeley y Turner, 2005) y considerando la Península y Baleares como una región conjunta.

La determinación de la configuración espacial se fundamenta en la comparación entre las propiedades de una distribución teórica aleatoria (distribución homogénea de Poisson) y las de la distribución observada. Esta distribución teórica aleatoria se corresponde con la Aleatoriedad Espacial Completa (*CSR*; *Complete Spatial Randomness*, en inglés), es decir, que no existe ningún patrón que regule la ubicación de los puntos en el área de estudio. De este modo se puede precisar si estos se distribuyen espacialmente de forma regular, aleatoria o agrupada (Cabrero Ortega y García Pérez, 2015; Olaya, 2014).

Para analizar la hipótesis *CSR* se consideraron los métodos basados en distancias (distancia Euclídea) de la localización más cercana (*función G*) y del espaciamiento medio (*función F*). La *función G* mide la distribución de las distancias desde un evento arbitrario a su evento más cercano, mientras que la *función F* mide la distribución de todas las distancias desde un punto arbitrario en el espacio hasta su evento más cercano (véase Baddeley, 2008, pp. 115–124; Bivand, Pebesma, y Gómez-Rubio, 2013, pp. 179–182; Cressie, 1993, pp. 636–639). Estas

funciones nos indican la variedad de distancias que cubren los puntos y si estos se encuentran bien repartidos en el espacio.

3.5.3. Representatividad de las elevaciones

El último paso consistió en explorar la representatividad de las elevaciones en comparación con la distribución de elevaciones del área de estudio mediante el análisis gráfico y la prueba de contraste de Kolmogorov-Smirnov. Previo a ello, se comprobó que las elevaciones registradas en los datos se correspondían con las extraídas del MDE en sus localizaciones por comparación lineal de ambas, siendo las primeras las consideradas como verdaderas.

3.5.4. Resumen

El esquema de la Figura 2 resume los pasos seguidos en el análisis exploratorio.

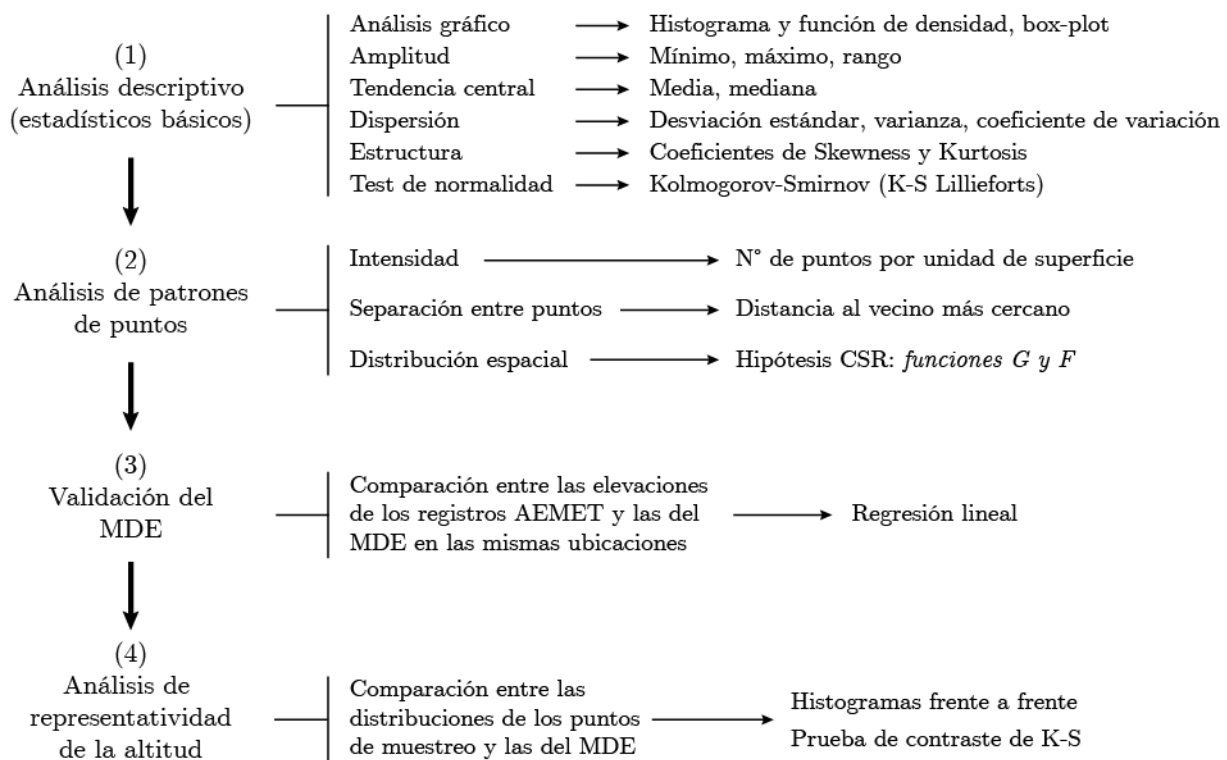


Figura 2. Diagrama de progresión del análisis estadístico exploratorio. Pasos, tipo de análisis y métodos o medidas.

3.6. Análisis espacial: el variograma

Los métodos de interpolación basados en distancias requieren que la variable objetivo presente continuidad espacial, es decir, que esté autocorrelacionada espacialmente (Cabrero Ortega y García Pérez, 2015). Para estudiar dicha correlación espacial y otras características de los datos se empleó el gráfico del variograma muestral (también llamado variograma experimental) directamente sobre los datos de $T_{máx}$ y T_{pr} .

Siguiendo el texto de Olaya (2014, pp. 303–308), los variogramas (o semivariogramas) se fundamentan en el concepto de semivarianza. La semivarianza es una medida de la disimilitud de una variable Z entre dos puntos s_i y s_j , y viene expresada por

$$\gamma(s_i, s_j) = \frac{1}{2} (Z(s_i) - Z(s_j))^2 \quad (6)$$

Los valores de γ se representan en función de las distancias (h) entre cada uno de los puntos formando una nube, luego se agrupan por intervalos de h y se calcula la media de todas las semivarianzas en cada intervalo según:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} (Z(s_i) - Z(s_i + h))^2 \quad (7)$$

siendo $N(h)$ el número de pares de puntos del conjunto de localizaciones separados entre sí por una distancia h .

Los puntos que forman el variograma muestral en clases de h (Figura 3) aportan la información sobre el proceso estudiado por medio de su forma y de unos elementos básicos que determinan varias propiedades de los datos. Estos elementos son:

Rango. El rango representa la máxima distancia a la cual existe dependencia espacial. Es el valor en el que se alcanza la máxima varianza o a partir del cual ya presenta una tendencia asintótica. En este último caso, la varianza es infinita y la distancia se establece donde el valor de semivarianza alcanza el 95% del *sill*. Esta distancia se conoce como el *rango efectivo* (Webster y Oliver, 2007).

Sill. El máximo del variograma. Representa la máxima variabilidad en ausencia de dependencia espacial (varianza parcial o estructural).

Nugget. Es el valor de la intercepción con el eje de ordenadas. Representa una variabilidad no espacial de la variable cuando h tiende a 0. El efecto *nugget* puede ser causado por la variabilidad a distancias muy cortas para las cuales no hay pares de observaciones disponibles, inexactitud del muestreo o inexactitud en los instrumentos utilizados para la medición (Cressie, 1993; Hengl, 2009).




Figura 3. Ejemplo de semivariograma. $\hat{\gamma}(h)$, semivarianza, h , distancia, C_0 , covarianza mínima; $C_0 + C_I$, covarianza máxima (Tomado de Hengl, 2009).

Posteriormente, sobre los puntos nombrados se define un modelo que implica el ajuste de una función matemática y cuyo resultado es la obtención de un variograma teórico. Según Hartkamp, De Beurs, Stein, y White (1999), las funciones más comúnmente utilizadas son la lineal, la esférica, la exponencial y la Gaussiana. Una vez ajustada, se pueden conocer las semivarianzas para cualquier distancia h y sirve como parte integrante de los métodos basados en la geoestadística.

La descripción para el ajuste del modelo de semivarianza y la elección del variograma correcto se puede leer en Cressie (1993, pp. 52–104), Hartkamp et al. (1999) y Webster y Oliver (2007, pp. 47–107).

3.6.1. Análisis visual de correlación espacial

El análisis visual de los variogramas muestrales se centró en examinar la existencia de *autocorrelación espacial* y el cumplimiento de los supuestos de *estacionariedad* e *isotropía*, esenciales para la aplicación de técnicas basadas en las distancias.

La suposición de estacionariedad asume que el proceso que generó la muestra proviene de una función aleatoria² $Z(s)$ cuya media y varianza son constantes en el espacio (Bivand et al., 2013; Cabrero Ortega y García Pérez, 2015). Dada la dificultad que esto ocurra en la realidad, se acepta que se cumpla la *hipótesis intrínseca* de estacionariedad (Cressie, 1993), definida por

$$E[Z(s + h) - Z(s)] = 0 \quad (8)$$

$$\text{var}[Z(s + h) - Z(s)] = 2\gamma(h) \quad (9)$$

² El conjunto de valores reales de Z que comprende la realización del proceso aleatorio $Z(s)$ se conoce como una *variable regionalizada* (Webster y Oliver, 2007).

con lo cual admitimos que existe un proceso aleatorio continuo en el espacio cuya varianza entre dos puntos s_i y s_j no depende de su localización, sino solamente de la distancia h que los separa.

Bajo este supuesto, la isotropía hace referencia a que la $\gamma(h)$ es invariante respecto a la dirección en que se tome dicho valor. El caso contrario se denomina anisotropía.

La falta de autocorrelación espacial se observa cuando no hay continuidad lineal en el variograma (comportamiento errático) o este se presenta con una gran discontinuidad en el origen (*nugget*) cercana al valor del *sill* (también llamado efecto *nugget puro*).

La falta de estacionariedad se diagnostica por variogramas cóncavos o con tendencia parabólica creciente de la varianza, así como por variogramas que aumentan bruscamente después de haber alcanzado un máximo de varianza.

Para evaluar la anisotropía, se representaron los variogramas en cuatro direcciones cuyas marcas de clase fueron 0° (Norte), 45° (Noreste), 90° (Este) y 135° (Sureste), con un grado de tolerancia de $22,5^\circ$. Se cumple isotropía cuando estos no presentan serias disimilitudes entre ellos. Se distingue entre anisotropía geométrica cuando difieren los rangos y anisotropía zonal cuando lo hacen los *sill*, e indican diferencias en la continuidad espacial y diferencias en la varianza, respectivamente.

3.6.2. Ajuste del modelo de semivarianza

Tras el análisis visual, se llevó a cabo el ajuste de la función matemática sobre el variograma muestral por la técnica de mínimos cuadrados ponderados, donde los pesos se atribuyeron al número de puntos en cada intervalo y a las distancias de estos (N_i/h_i^2). Con ello se pretendió dar mucha más importancia a las semivarianzas calculadas con un gran número de pares de puntos y a distancias más cortas.

El procedimiento en `gstat` (Pebesma, 2004) requiere de los parámetros iniciales de *rango*, *sill* y *nugget*. Como norma general, se estableció:

- *Rango*: Distancias de h en 100, 150, 200 y 250 km para ambas variables.
- *Sill*: El total de la varianza no espacial de la variable objetivo, $S^2(Z(s))$.
- *Nugget*: Zero, 0.

Del mismo modo, los modelos matemáticos Circular, Esférico, Penta-esférico y Exponencial se consideraron adecuados para explicar la estructura espacial de las variables predefinidas, y se añadió el modelo Gaussiano a la variable T_{pr} .

Con este conjunto de valores se automatizó el proceso de ajuste por iteración, enfocado a minimizar el error obtenido tras hacer una validación cruzada (véase el apartado 3.8). Se adoptó el modelo ajustado que generó el mínimo error.

3.6.3. Valores atípicos espaciales

Si a los atributos de la variable le sumamos la componente espacial, los valores anómalos en relación con los de su entorno más próximo se denominan *valores atípicos espaciales*. De manera análoga a lo expuesto en el apartado 3.4.3, su presencia puede afectar negativamente a las superficies generadas en la interpolación. Su extracción puede ayudar a corregir las incoherencias topológicas de los datos y a mejorar la precisión del modelo de varianza (Olaya, 2014).

La detección de valores atípicos espaciales se realizó mediante el *algoritmo z* descrito por (Lu, Chen, y Kou, 2003), el cual se aplicó a los valores normalizados de los residuos (*z-score*) obtenidos de la validación cruzada en el proceso de ajuste del variograma teórico (véase apartado 3.6.2).

Estos valores *z* se obtienen de

$$z_i = \frac{Z(s_i) - \hat{Z}_{[i]}(s_i)}{\sigma_{[i]}(s_i)} \quad (10)$$

donde el numerador corresponde a los residuos de la validación y $\sigma_{[i]}(s_i)$ es la estimación de la variación (error estándar) en cada punto s_i (Bivand et al., 2013). Los valores *z* suponen una medida de posición relativa a una distribución normal teórica con media 0 y varianza 1.

Tras varias pruebas, se consideraron valores espacialmente discordantes los que excedían de 3 desviaciones estándar de la distribución del error de predicción normalizado.

Una vez extraídos, se procedió de nuevo a ajustar el variograma teórico sin la influencia de estos valores.

3.7. Proceso de interpolación

Los métodos de interpolación empleados para generar las superficies continuas de las variables de interés a todo el territorio fueron la regresión lineal (RL), el método de ponderación por el inverso de la distancia (IDW) y el método de *kriging* ordinario (OK).

Los aplicativos para los cálculos en R fueron la función `lm` del paquete integrado `stats` y las funciones `idw` y `krige` de la librería `gstat`, en este orden.

3.7.1. Regresión lineal

El ajuste de funciones de regresión lineal es una herramienta estadística que permite predecir valores mediante la correlación de unas variables explicativas y la variable de interés, basándose en una cierta apreciación de la naturaleza física de los fenómenos, pero sin tener en cuenta las relaciones espaciales de dicha variable consigo misma (Webster y Oliver, 2007).

En este trabajo se probaron, como métodos directos de interpolación, dos modelos de regresión lineal basados en la *longitud* (x), la *latitud* (y) y la *elevación* (e). Para ello, se utilizaron todos los datos disponibles en la zona de estudio, sin extraer previamente los valores atípicos espaciales.

El primer modelo (RL1; Ec.11) fue un modelo simplificado de regresión lineal múltiple de la forma

$$Z = \beta_0 + \beta_1 e + \beta_2 x + \beta_3 y + \varepsilon \quad (11)$$

donde β_0 es el valor de la intercepción con el eje de ordenadas, $\beta_{n>0}$ son los coeficientes de la regresión y ε es el error aleatorio de la predicción.

El segundo modelo (RL2; Ec.12) fue desarrollado por Sánchez-Palomares, Sánchez-Serrano, y Carretero (1999) para cada una de las 10 principales cuencas de la Península Ibérica por medio del análisis de regresión múltiple por etapas, cuya fórmula común adopta la siguiente expresión:

$$Z = \beta_0 + \beta_1 \left(\frac{e}{10^3}\right) + \beta_2 \left(\frac{x}{10^5}\right) + \beta_3 \left(\frac{y}{10^5}\right) + \beta_4 \left(\frac{x}{10^5}\right)^2 + \beta_5 \left(\frac{y}{10^5}\right)^2 \quad (12)$$

Los coeficientes de ambos modelos se ajustaron diariamente por el método de mínimos cuadrados ordinarios y se comprobó, de manera visual, el cumplimiento de las asunciones de linealidad, independencia, homocedasticidad y normalidad, así como la influencia de ciertos valores y otros efectos indeseados sobre los residuos.

Los supuestos de linealidad y homocedasticidad se analizaron por medio de los gráficos de los residuos frente a los valores predichos. La normalidad de los residuos se observó a través de los gráficos *cuantil-cuantil*, que muestran los residuos estandarizados de la regresión frente a una distribución normal teórica. La autocorrelación (independencia) se examinó por observación de tendencias en los gráficos de residuos sucesivos antepuestos. Por último, el gráfico de los residuos estandarizados frente a los valores de apalancamiento³ (*leverage*) se usó para detectar valores atípicos y valores influyentes en las observaciones.

Para saber qué modelo era mejor para cada variable, se compararon los resultados de la regresión entre ambas funciones y se calcularon los valores del Criterio de Información de Akaike (AIC):

$$AIC = n \log\left(\frac{RSS}{n}\right) + 2(p + 1) \quad (13)$$

³ Un punto de apalancamiento (*leverage point*) se define como una observación que tiene un valor de z que está muy lejos de la media de z .

donde RSS es la suma de los cuadrados de los residuos, n es el tamaño de la muestra y p el número de parámetros del modelo. El modelo con menor AIC se considera el estimador de máxima verosimilitud y el más simple, conforme al *Principio de Parsimonia* (Akaike, 1974; T. Wu y Li, 2013).

3.7.2. Ponderación por el Inverso de la Distancia

La interpolación basada en la ponderación por el inverso de la distancia (IDW) es un método determinístico, convexo y exacto (Hengl, 2009). Esto es, que solo produce estimaciones de la variable objetivo sin un error asociado, que los máximos y mínimos solo ocurren en los puntos observados y que estos se mantienen iguales en la superficie generada (Li y Heap, 2011).

El valor de la variable objetivo en cualquier localización es calculado a partir de un promedio ponderado:

$$Z^*(s_0) = \sum_{i=1}^n \omega_i Z(s_i) \quad (14)$$

donde $Z^*(s_0)$ es el valor estimado de la variable Z en la localización s_0 , ω_i corresponde al peso asociado con el valor observado de Z en el punto muestral s_i y n es el número de valores observados cercanos utilizados en la estimación de s_0 .

El enfoque más simple para determinar los pesos, y en el que se basa este método, es usar las distancias inversas desde todos los puntos hasta el nuevo punto:

$$w_i(s_0) = \frac{1}{\frac{|s_0 - s_i|^k}{\sum_{i=0}^n \frac{1}{|s_0 - s_i|^k}}}; \quad k > 1 \quad (15)$$

donde $|s_0 - s_i|$ es la distancia entre la nueva localización y el punto de muestreo con valor conocido de Z y k es el coeficiente arbitrario que se usa para ajustar los pesos. La suma total necesita ser igual a uno ($\sum_{i=1}^n \omega_i = 1$) para garantizar un interpolador imparcial.

La asignación del parámetro k se llevó a cabo por iteración de valores con el criterio de minimizar el error obtenido de una validación cruzada.

Para este fin se desarrolló un algoritmo automático, con estructuras condicionales y estructuras de repetición, en el que se introducía un valor k inicial para comenzar un proceso de iteración paso a paso hasta conseguir el grado de precisión deseado. La función compara el error calculado para un valor de $k0$ con un valor de $k1$ equivalente siempre a $k0+p$, siendo p la unidad de precisión ($p= 1; 0,1; etc.$). La estructura condicional decide hacia qué lado irá la iteración según si $e_{k0} > e_{k1}$ o $e_{k0} < e_{k1}$, sumando o restando p a $k0$ e iniciando de nuevo la comparación.

Para este trabajo se optó por un nivel de precisión decimal.

3.7.3. Kriging Ordinario

El *kriging* ordinario (OK) es un método estocástico, exacto y local que, al igual que IDW, utiliza una combinación lineal de pesos en puntos conocidos de la variable de interés para predecir su valor en un punto desconocido (Hartkamp et al., 1999).

Los métodos estocásticos incorporan el concepto de aleatoriedad y proporcionan tanto estimaciones (parte determinista) como errores asociados, es decir, incertidumbres representadas como varianzas estimadas (parte estocástica) (Li y Heap, 2011). Se puede representar con el modelo general

$$Z(s) = \mu + \varepsilon(s) \quad (16)$$

donde μ representa la tendencia global (media global constante en toda la región de estudio) y $\varepsilon(s)$ es la componente aleatorio de la varianza correlacionada espacialmente (Hengl, 2009). Esto indica que se debe cumplir con los supuestos de las variables regionalizadas (estacionariedad e isotropía) descritas en el apartado 3.6.1.

Bajo el supuesto de *estacionariedad intrínseca* se asume que esta tendencia global es desconocida y se substituye μ por una media local $\mu(s)$, que es la media de las muestras dentro de un entorno reducido en el espacio (Webster y Oliver, 2007).

El estimador del método de OK se expresa del mismo modo que la Ec.14. Los pesos ω_i son forzados a cumplir con la condición de $\sum_{i=1}^n \omega_i = 1$. y se determinan a partir del modelo ajustado de semivarianza (modelo del variograma teórico) de modo que la varianza estimada del error se minimice (Hengl, 2009).

3.8. Validación estadística de los métodos de interpolación

Para evaluar las predicciones realizadas con los distintos métodos de interpolación basados en distancias se utilizó la técnica de la validación cruzada (*cross-validation*, en inglés), en su variante llamada *leave-one-out cross-validation* (LOO). Esta técnica no requiere de un set de datos independiente; cada punto de muestreo del set original es usado para la validación cruzada.

El proceso consiste en eliminar un punto cada vez y predecir el valor en su ubicación con *kriging* sin usar el valor observado, luego se continua con el siguiente punto hasta obtener la matriz completo de pares de valores con los que poder calcular los residuos (diferencia entre los valores observados y los valores predichos) y, por consiguiente, el error.

LOO se implementó con la función `krige.cv` del paquete `gstat` y su desarrollo teórico se puede encontrar en Hengl (2009, pp. 25–26), Bivand et al. (2013, pp. 247–248) y Rossiter (2017, pp. 96–97).

La comparación del rendimiento de los distintos métodos de interpolación y de los ajustes de los variogramas se hizo a través del cálculo del error medio (MBE), el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE). El primero es usado para determinar el grado de exactitud o sesgo de las estimaciones y los segundos son medidas de la precisión de las estimaciones. La diferencia es que MAE es menos sensible a valores extremos (Li y Heap, 2011) mientras que RMSE supone un estimador más robusto cuando la existencia de errores altos es particularmente indeseable (T. Wu y Li, 2013). Sus expresiones son:

$$\text{MBE} = \frac{1}{n} \sum_{i=1}^n (o_i - p_i) \quad (17)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |o_i - p_i| \quad 100 \quad (18)$$

$$\text{RMSE} = \left[\frac{1}{n} \sum_{i=1}^n (o_i - p_i)^2 \right]^{1/2} \quad 100 \quad (19)$$

donde o_i son los valores observados, p_i son los valores predichos y n es el tamaño de la muestra.

Al mismo tiempo, se calculó el coeficiente de determinación R^2 definido por

$$R^2 = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (o_i - \bar{o})^2} \quad (20)$$

donde \bar{o} es la media de los valores observados. R^2 expresa la proporción de la varianza original contabilizada por las estimaciones del modelo; es una medida de efectividad del modelo.

Adicionalmente, se hizo una valoración del error absoluto medio de estimación del déficit de presión de vapor (MAE_D) y de la humedad de los combustibles finos muertos (MAE_D). Ambas variables se estimaron a partir de los valores promediados de los percentiles 50 y 95 derivados de las observaciones de $T_{\text{máx}}$ y T_{pr} en el periodo de estudio. Estos cálculos se hicieron según las dos variables interpoladas por separado. Se fijó un valor medio observado de humedad relativa para la $T_{\text{máx}}$ y de temperatura máxima para la T_{pr} , que se correspondía con los registros de $T_{\text{máx}}$ y T_{pr} de cada percentil. MAE_D y MAE_{FM} se determinaron por la media aritmética de los valores absolutos conseguidos tras sumar y restar el valor de MAE obtenido, para cada variable, en la evaluación de los distintos métodos de interpolación.

3.9. Definición de los umbrales críticos de humedad

La definición de los umbrales críticos de humedad de los combustibles finos muertos se llevó a cabo a partir del trabajo realizado por Boer et al. (2017) en la región de Portugal, basado a su vez en el estudio previo de Nolan, Boer, et al. (2016).

Se trata de un índice categórico que se fundamenta en la relación entre el contenido de humedad de los combustibles finos muertos y los incrementos bruscos en el área quemada acumulada.

El estudio hecho en Portugal para el periodo de 2001-2015 (Figura 4) dictaminó que muy poca superficie forestal se quemó cuando la humedad de los combustibles (FM) excedió del 26%, lo cual coincide con los contenidos de humedad de extinción⁴ de 25%-35% para los combustibles leñosos. El 87% del área quemada acumulada ocurrió cuando FM era igual o inferior al 18% mientras que el umbral del 12% de FM provocó un incremento significativo traducido en grandes áreas quemadas (Boer et al., 2017).




Figura 4. Relación entre el área acumulada quemada por los incendios forestales en Portugal (2001-2015) y el contenido de humedad de los combustibles finos muertos (FM) estimado. Las barras grises verticales representan el intervalo de confianza del 95% de los umbrales críticos de humedad del combustible. Extraído de Boer et al. (2017).

Visto lo anterior, los umbrales críticos que definen la disponibilidad para arder de los combustibles finos muertos se establecieron en 26%, 18% y 12%, según se muestra en la Tabla 1.

⁴ La humedad de extinción se define como el contenido de humedad de un combustible por encima del cual no se puede sostener un incendio (Rothermel, 1972). En los combustibles muertos puede variar entre el 12 y el 40 %, dependiendo del tipo de combustible (Aguado et al., 2007).

Tabla 1. Definición de los umbrales críticos de humedad de los combustibles finos muertos (FM) según Boer et al. (2017). Relación entre las categorías de disponibilidad de los combustibles finos muertos, los valores críticos de FM y su representación colorimétrica.

Código	Disponibilidad de los combustibles finos muertos	Valores críticos de FM (%)	Color (código HEX)
U1	Baja	>26	Verde (#D1FF73)
U2	Moderada	26-18	Amarillo (#FFFF73)
U3	Alta	18-12	Naranja (#FFAA00)
U4	Muy alta	<12	Rojo (#E60000)

3.10. Resumen del proceso de interpolación

La Figura 5 muestra el resumen metodológico de la interpolación con las técnicas analizadas en este trabajo.

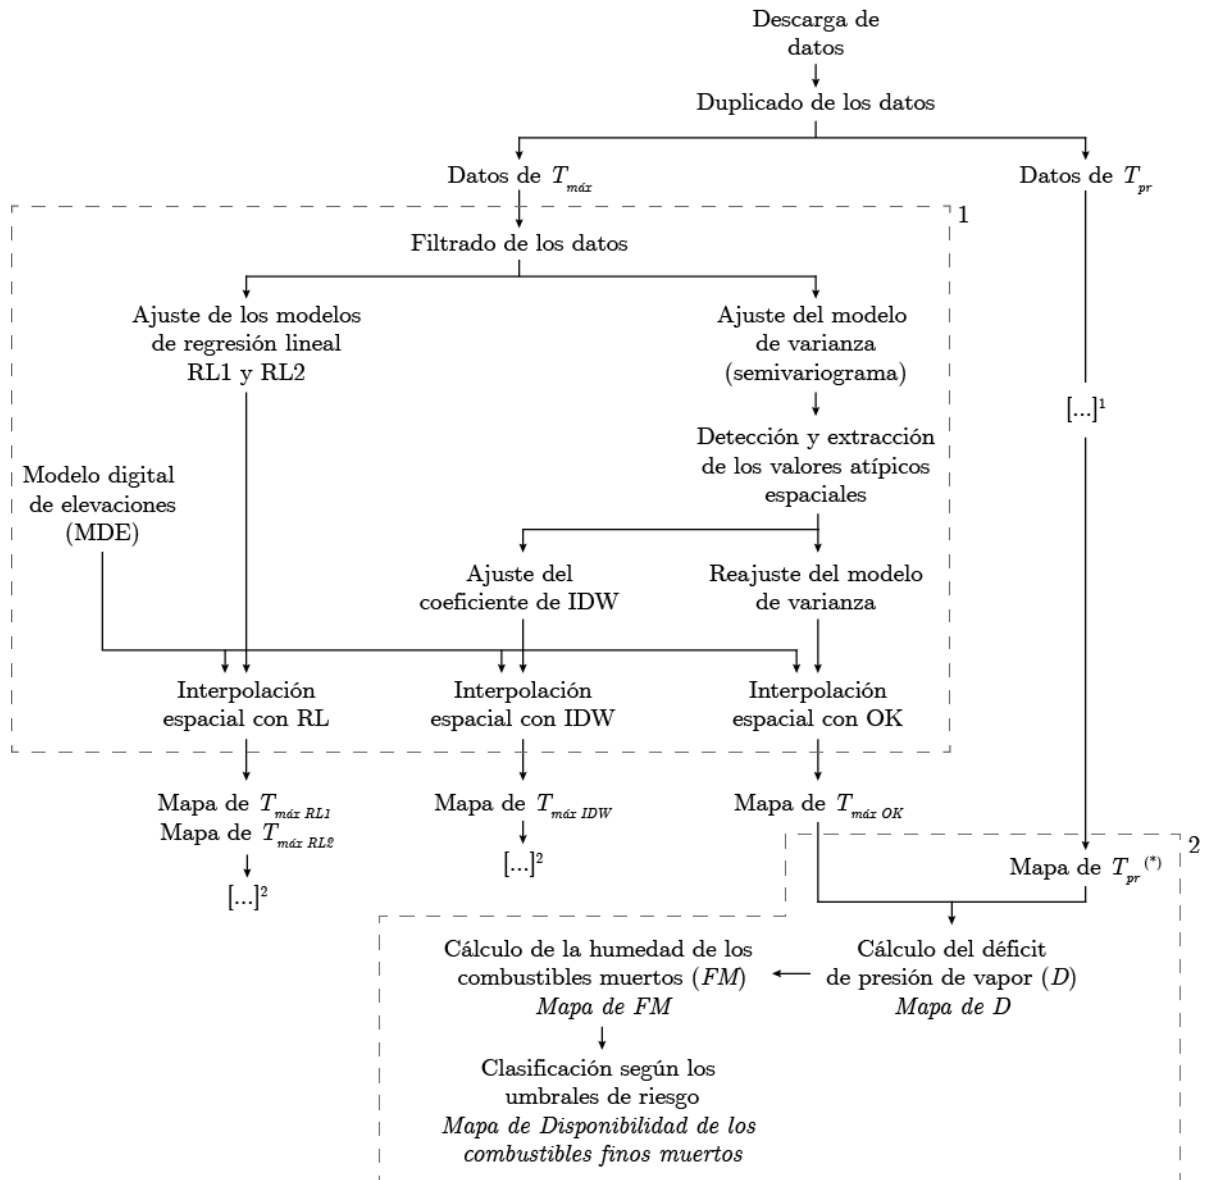


Figura 5. Diagrama resumen del proceso metodológico. [...] indica que se repiten los pasos que engloba el recuadro numerado con la línea discontinua. (*) cada método de interpolación combina sus propios mapas de temperatura máxima ($T_{máx}$) y temperatura en el punto de rocío (T_{pr}).

4. Resultados y análisis

4.1. Análisis estadístico exploratorio

4.1.1. Descripción de los datos

El resumen de los estadísticos descriptivos se muestra en la Tabla 2. De forma general, los valores de tendencia central difirieron en un promedio de 0,01 (1,1%) respecto a un valor ideal de normalidad (relación media/mediana igual a 1). Se obtuvo un rango de valores amplio en ambos casos, con mayor semejanza entre los registros de junio y julio en la $T_{máx}$ que los mismos registros en la T_{pr} . Al mismo tiempo, la $T_{máx}$ presentó un coeficiente de variación más bajo que el de la T_{pr} , y se mostró más constante durante todo el periodo de estudio.

Estructuralmente, no se intuyó una tendencia marcada al apuntamiento o achatamiento de las distribuciones; no obstante, estas fueron ligeramente platicúrticas para la $T_{máx}$ (valores negativos de *Kurtosis*) y leptocúrticas para la T_{pr} (valores positivos de *Kurtosis*). En cuanto al sesgo, ambas variables manifestaron un leve desplazamiento hacia la izquierda con respecto a los valores centrales de las distribuciones (valores negativos de *Skewness*). No obstante, no fue suficiente para determinar con claridad que dichas distribuciones fueran asimétricas.

Estadísticamente, los resultados de la prueba de Lilliefort devolvieron valores generales de probabilidad (*p-valores*) inferiores a un nivel crítico del 0,05 para la $T_{máx}$ y superiores para la T_{pr} , lo cual indica la normalidad de esta última y rechaza la hipótesis en la primera.

Tabla 2. Estadísticos descriptivos de los datos observados para la temperatura máxima diaria y la temperatura en el punto de rocío. Valores promedio de los meses de junio, julio y totales.

		N ^b	m ^b	M ^b	mín ^b	máx ^b	S.D. ^b	var. ^b	CV ^b	Skew ^b	Kurt ^b
$T_{máx}^a$	Junio	710	25,27	25,44	12,44	35,30	4,12	17,34	16,68	-0,287	-0,223
	Julio	702	29,27	29,81	15,28	38,73	4,21	17,96	14,44	-0,501	-0,184
	Total	706	27,30	27,66	13,88	37,04	4,17	17,66	15,54	-0,396	-0,204
T_{pr}^a	Junio	707	12,14	12,22	-0,50	22,77	3,32	11,23	27,59	-0,208	0,505
	Julio	699	12,83	13,01	-5,81	25,89	4,88	24,60	38,57	-0,312	0,091
	Total	703	12,49	12,62	-3,20	24,35	4,11	18,03	33,17	-0,261	0,294

^a $T_{máx}$, temperatura máxima del aire (°C); T_{pr} , temperatura del punto de rocío (°C).

^b N, cantidad válida de puntos de muestreo; m, media aritmética; M, mediana aritmética; mín, mínimo; máx, máximo; S.D., desviación estándar; var., varianza (°C²); CV, coeficiente de variación (%); Skew, coeficiente de asimetría (*Skewness*); Kurt, coeficiente de apuntamiento (*Kurtosis*)

La Figura 6 muestra varios casos de la distribución de densidad de las variables $T_{m\acute{a}x}$ y T_{pr} . En gran parte de los histogramas se distingue, con mayor o menor grado, la formación de dos picos (máximos) en las funciones de distribución, indicativo de la existencia de distintas estructuras. A pesar de ello, en la mayoría de los casos no hubo evidencias de que las distribuciones fueran visiblemente asimétricas, ni que difirieran mucho de una distribución normal con los mismos parámetros de media y desviación típica.

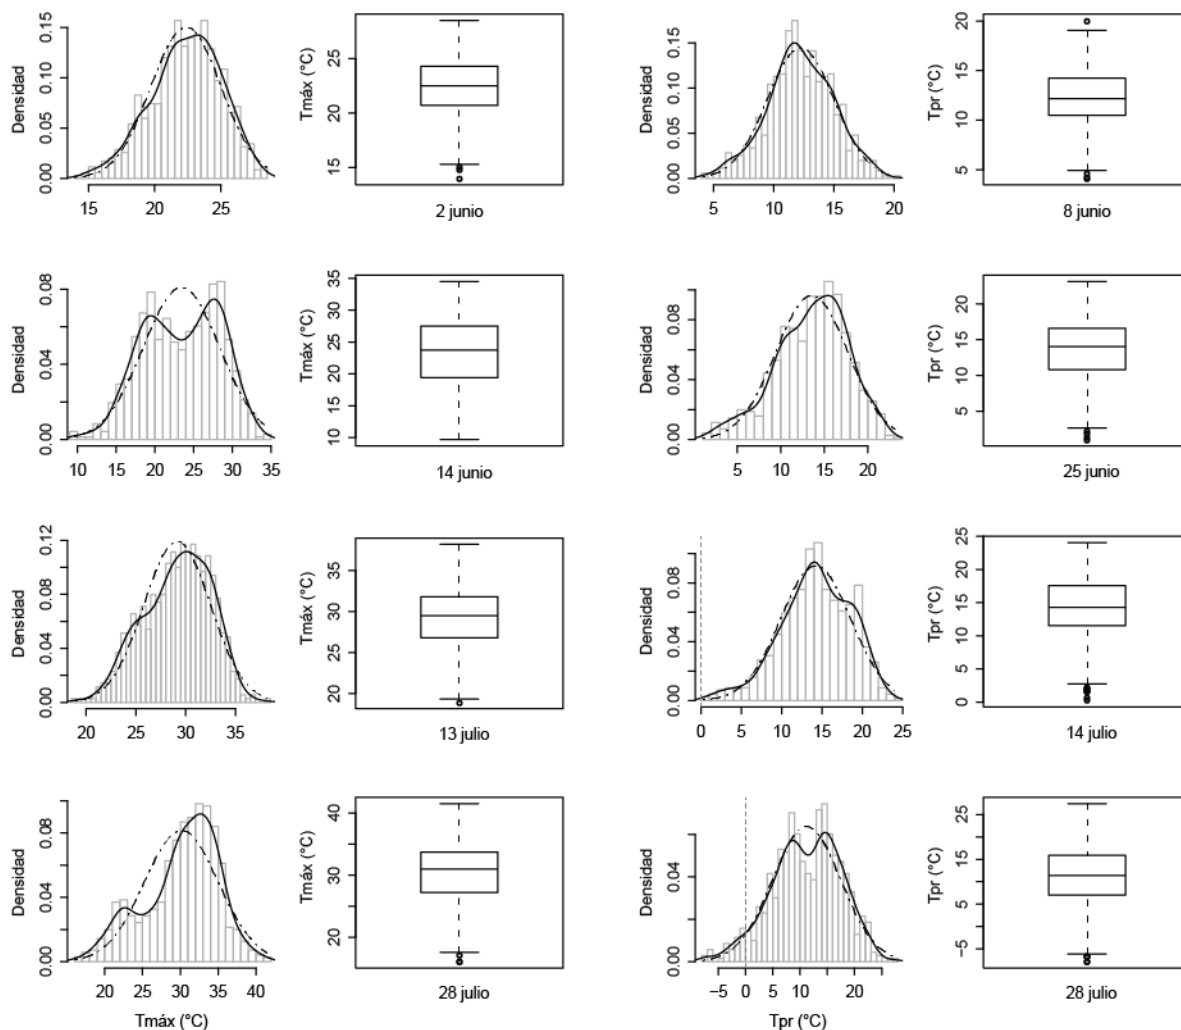


Figura 6. Ejemplos de histogramas de densidad y diagramas de caja representativos de las variables temperatura máxima ($T_{m\acute{a}x}$; izquierda) y temperatura en el punto de rocío (T_{pr} ; derecha). Histograma: la línea continua indica la función de distribución de la variable; la línea discontinua hace referencia a una distribución normal con media y desviación estándar igual a las de la distribución observada.

4.1.2. Distribución espacial de los puntos de muestreo

El número promedio de puntos correspondiente a las estaciones meteorológicas donde se adquirieron los datos fue de 706 y 703 para $T_{m\acute{a}x}$ y T_{pr} respectivamente, en una superficie de

estudio de 502 494 km². Esto equivale a una intensidad media de 1 punto por cada 712 y 715 km². El tamaño de celda de los mapas continuos asociado a esta densidad de puntos fue de 2500 m x 2500 m, correspondiente a una superficie homogénea de 6,25 km².

En el análisis de la distribución de los puntos de muestreo (Figura 7) se observó que las distancias al vecino más cercano fueron ligeramente más amplias que las de la distribución aleatoria CRS ($G_{obs}(r) < G_{teo}(r)$). Estas distancias oscilaron entre los 0,16 y 45,6 km, con un valor promedio de 17,2 km.

Al mismo tiempo, el espacio vacío entre puntos fue levemente superior al esperado ($F_{obs}(r) > F_{teo}(r)$). No obstante, la línea de distribución de los valores observados no sobrepasó el intervalo de confianza del 0,04⁵ de la distribución teórica.

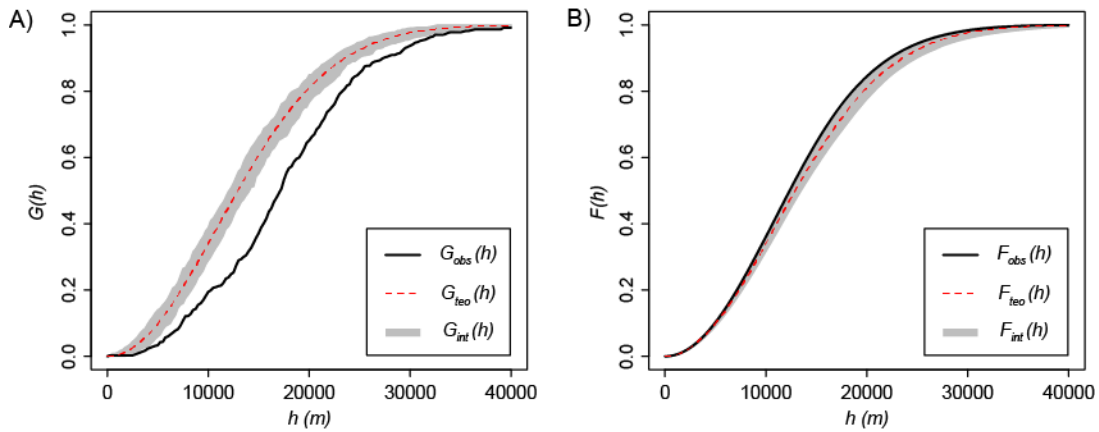


Figura 7. Contraste de Aleatoriedad Espacial Completa (CRS) y la distribución de puntos observada (A, función G ; B, función F) para un número promedio de puntos de muestreo válidos, con los límites del intervalo de confianza del 96% sobre 100 simulaciones de CRS. *obs*, distribución observada; *teo*, distribución teórica; *int*, intervalo de confianza.

4.1.3. Representatividad de las elevaciones

Para un número promedio de estaciones, el MDE mostró buena relación con las elevaciones de los datos AEMET ($R^2=0,96$, MAE=46,7 m). El valor de la intercepción fue ligeramente distinto de 0 ($\beta_0=18,5$) mientras que la pendiente fue cercana al 1 ($\beta_1=0,95$), con un nivel de significación p del 0,05 en ambos casos (Figura 8B). Según estos resultados, no hubo motivos para no otorgar la validez al MDE empleado en este estudio.

En cuanto a la representatividad, en el gráfico de la Figura 8A se observa un sobredimensionado de puntos de muestreo en el intervalo comprendido entre los 0 y 200 m, y una ligera falta de representación por encima de los 1200 m que se convierte en nula a partir

⁵ De 100 simulaciones de distribución aleatoria CSR se eliminaron 2 de cada extremo para construir los límites del intervalo de confianza.

de los 2000 m de altitud. No obstante, el contraste de hipótesis global (*prueba KS*) devolvió un *p-valor* de 0,06 y un valor de correlación de Pearson de 0,8, ambos evaluados sobre un nivel de confianza del 95%. Esto se traduce en que no hubo una diferencia significativa entre la distribución de elevaciones de los puntos de muestreo y la distribución de elevaciones del área de estudio.

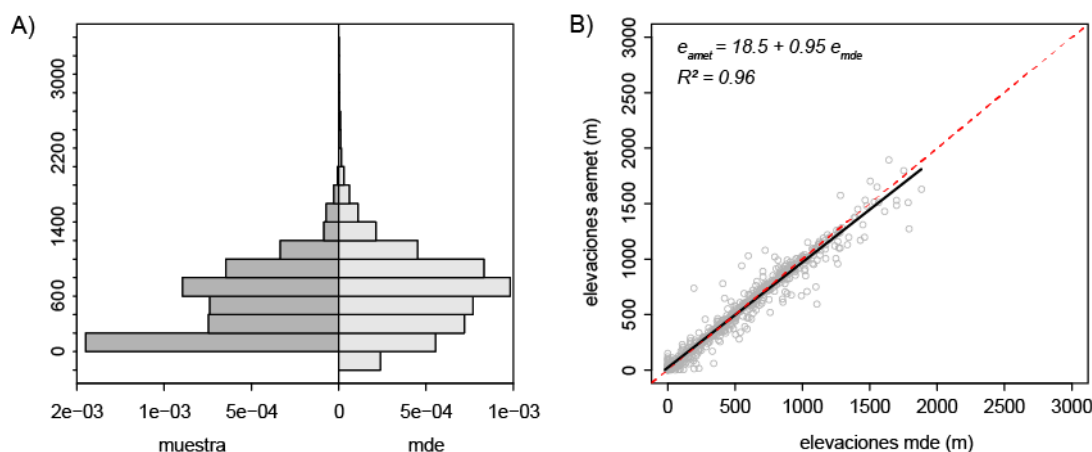


Figura 8. A. Histograma comparativo de la altitud de los puntos de muestreo (estaciones meteorológicas) y las elevaciones del área de estudio extraídas del modelo digital del terreno. B. Correspondencia entre las elevaciones de las estaciones AEMET y las elevaciones obtenidas del MDE en las mismas localizaciones. La línea discontinua roja indica la relación 1:1; la línea continua negra es la recta de la regresión.

4.2. Análisis espacial

4.2.1. Análisis visual

Los variogramas muestrales isotrópicos y anisotrópicos obtenidos de los datos en el periodo comprendido entre el 1 de junio y el 31 de julio se pueden ver en el Anexo 2. De forma general, se consideró adecuada una amplitud del intervalo de representación de la distancia (h) de 10 km para los variogramas isotrópicos y de 20 km para los anisotrópicos.

Los variogramas de la $T_{máx}$ mostraron un incremento inicial lineal, constante y monótonico de la semivarianza hasta alcanzar aproximadamente una distancia de 200 km; lo cual confirma la existencia de autocorrelación espacial. A esa distancia parecía que se alcanzaba el *sill*, sin embargo, se producía un aumento generalizado más o menos brusco de la semivarianza sin que se llegara a un máximo constante o asintótico dentro de la distancia de observación⁶.

⁶ El valor predeterminado que usa *gstat* para la ventana de observación es un tercio de la diagonal más grande del cuadro delimitador de los datos, en coordenadas. Este hecho se fundamenta en que para

En el caso de la T_{pr} , el comportamiento en el origen fue similar a la $T_{máx}$. Si bien se observaron mayores fluctuaciones a distancias próximas y entre intervalos, la tendencia general fue creciente y monótona. La aparente estabilización del *sill* fue más difusa que en la $T_{máx}$, pero se alcanzaba entre los 200 km y los 350 km, aproximadamente.

Considerando las distancias antes nombradas (200 km para $T_{máx}$ y 200-350 km para T_{pr}), del análisis anisotrópico se obtuvo que los variogramas direccionales alcanzaban el *sill* aproximadamente en un mismo *rango* y los *nuggets* se mostraban muy similares en todas las direcciones representadas. Este comportamiento define la falta de anisotropía geométrica, es decir, por diferencias significativas en la continuidad espacial. Por el contrario, fue común detectar (aunque no de forma unívoca) una menor varianza en la dirección este (longitud) que cuando se añadía la componente norte (latitud), más bien definida para la $T_{máx}$ que para la T_{pr} . Esto es indicativo de la existencia de anisotropía zonal.

4.2.2. Ajuste del modelo de semivarianza

Tras el análisis de los variogramas muestrales, se detectaron serios problemas de estacionariedad a nivel regional. Una forma de corregir esta falta de estacionariedad es restringiendo la media de $Z(s)$ a una escala más pequeña; entonces se asume que la estacionariedad se cumple localmente (Webster y Oliver, 2007). Esto se consigue, en parte, reduciendo el límite del variograma muestral a una distancia de observación más corta (Bivand et al., 2013; Gallardo, 2006). En este caso, se estableció un límite de 250 km acorde con las distancias anteriores, más un margen prudencial añadido a esa aproximación. Además, se simplificó el proceso de ajuste tomando como modelo experimental el variograma isotrópico.

El resumen de los modelos y los parámetros de los variogramas teóricos ajustados se muestran en las Tablas 3 y 4, respectivamente. Los resultados diarios y los gráficos de los variogramas se pueden consultar en el Anexo 3.

De forma común, el tipo de ajuste más utilizado fue el exponencial. En el caso de la $T_{máx}$ el dominio fue claro (86,9%) mientras que, en la T_{pr} , el uso de una función fue más disperso. En todos los ajustes se obtuvo un *nugget* positivo relativamente bajo o moderado en relación con el *sill*. En promedio, esta relación fue del 16% para la $T_{máx}$ y del 20,5% para la T_{pr} . No obstante, para esta última, el 25% (3r cuantil) de las veces la relación fue superior al 29,8% y se llegó a alcanzar un porcentaje máximo del 47,5%. En la Figura 9 se puede ver que la mayor parte de los *rangos* de la $T_{máx}$ fueron inferiores o cercanos a h . Por el contrario, en la T_{pr} , los *rangos* sobrepasaron dicha distancia el 50% de los días. Cabe destacar que, el incremento con el tiempo de los parámetros *nugget* y *sill* que se observa en la T_{pr} parece estar asociado al aumento de la varianza del mes de julio detectado anteriormente en el análisis exploratorio de la variable (Tabla 2, pág. 27).

distancias más largas existen menos pares de puntos y aparecen oscilaciones salvajes que revelan poco sobre el proceso bajo estudio (Bivand et al., 2013).

Tabla 3. Tipos de ajuste de los variogramas teóricos para la temperatura máxima ($T_{m\acute{a}x}$) y la temperatura en el punto de rocío (T_{pr}).

Tmáx					Tpr				
Modelo	Exp ^a	Sph ^a	Cir ^a	Pen ^a	Exp ^a	Sph ^a	Cir ^a	Pen ^a	Gau ^a
n° días	53	3	3	2	29	5	10	13	4

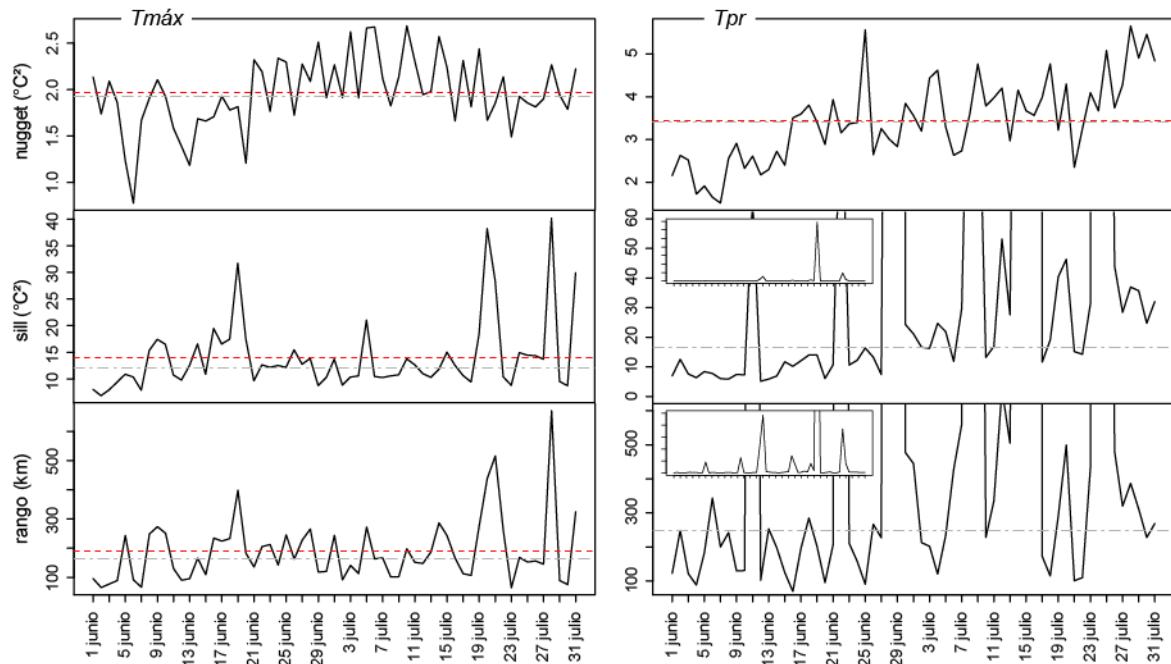
^a Exp, exponencial; Sph, esférico; Cir, circular; Pen, penta-esférico; Gau, Gaussiano.

Tabla 4. Resumen de los parámetros de los variogramas teóricos para la temperatura máxima ($T_{m\acute{a}x}$) y la temperatura en el punto de rocío (T_{pr}).

	Tmáx					Tpr				
	m ^a	M ^a	mín ^a	máx ^a	S.D. ^a	m	M	mín	máx	S.D.
nugget ^b	1,96	1,93	0,78	2,69	0,38	3,43	3,40	1,52	5,66	0,98
sill ^b	14,06	12,18	6,86	40,18	6,81	316,29	16,38	5,17	13857,3	1784,92
rango ^b	189,19	163,28	64,08	671,64	111,32	3951,87	246,66	67,85	143164	18605,0

^a m, media aritmética; M, mediana aritmética; mín, mínimo; máx, máximo; S.D., desviación estándar

^b unidades de nugget y sill: °C²; unidades del rango: km.

**Figura 9.** Parámetros de los variogramas teóricos obtenidos para la temperatura máxima ($T_{m\acute{a}x}$) y para la temperatura en el punto de rocío (T_{pr}) en el periodo de estudio. La línea discontinua roja indica la media aritmética; la línea discontinua gris representa la mediana aritmética.

Visualmente, la $T_{m\acute{a}x}$ mostr3 siempre un comportamiento lineal en el origen (Figura 10A) y un ajuste aceptable a la estructura de puntos que formaba el variograma experimental dentro del rango de observaci3n establecido.

Menos satisfactorios fueron, en ciertas ocasiones, los resultados de la T_{pr} . Como ejemplo, en la Figura 10B se ajust3 el modelo Gaussiano seg3n criterio de m3nimo error, cuyo comportamiento parab3lico inicial no corresponde con la estructura espacial que muestra la variable. Por otro lado, fue com3n detectar una varianza mayor en el primer intervalo de 10 km (Figura 10C y D). Se intuye que el fen3meno observado tiene un comportamiento irregular por debajo de esa distancia, el cual puede derivar puntualmente en una mala elecci3n de la funci3n de semivarianza (Figura 10D).

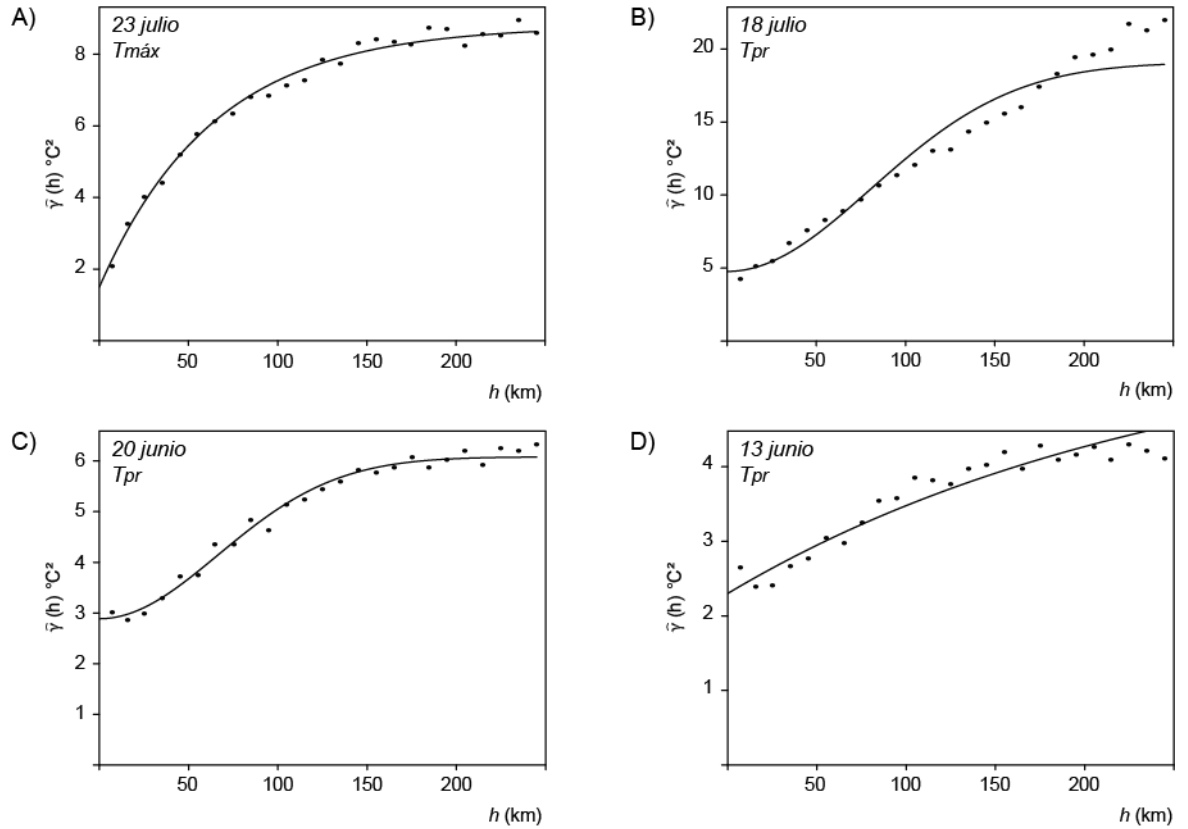


Figura 10. Ejemplos de variogramas te3ricos de la temperatura m3xima ($T_{m\acute{a}x}$; A) y la temperatura en el punto de roc3o (T_{pr} ; B, C y D). $\hat{\gamma}(h)$, semivarianza; h , distancia.

4.2.3. Valores atípicos

La proporción de *valores atípicos espaciales* extraídos giró en torno al 1,2% y al 1,3% para la $T_{máx}$ y la T_{pr} , respectivamente.

En la $T_{máx}$, estos valores fueron mayoritariamente registros bajos procedentes de estaciones situadas en zonas altas de montaña o en puntos contiguos a la costa (Figura 11). En cambio, los datos extraídos de la T_{pr} fueron más dispares (valores altos y bajos) y su patrón de distribución no resultó tan claro como el de la $T_{máx}$ (Figura 12).

En ambos casos, su extracción supuso una disminución notable de la varianza del *nugget*, un mejor ajuste inicial del variograma teórico y una reducción media del error de estimación del 5,8% y del 7,1% para la $T_{máx}$ y la T_{pr} , respectivamente, obtenido tras una validación cruzada hecha con el método de OK.

Por otra parte, el filtrado inicial de *valores atípicos globales* fue despreciable o completamente nulo en ambos casos ($T_{máx}$ y T_{pr}).

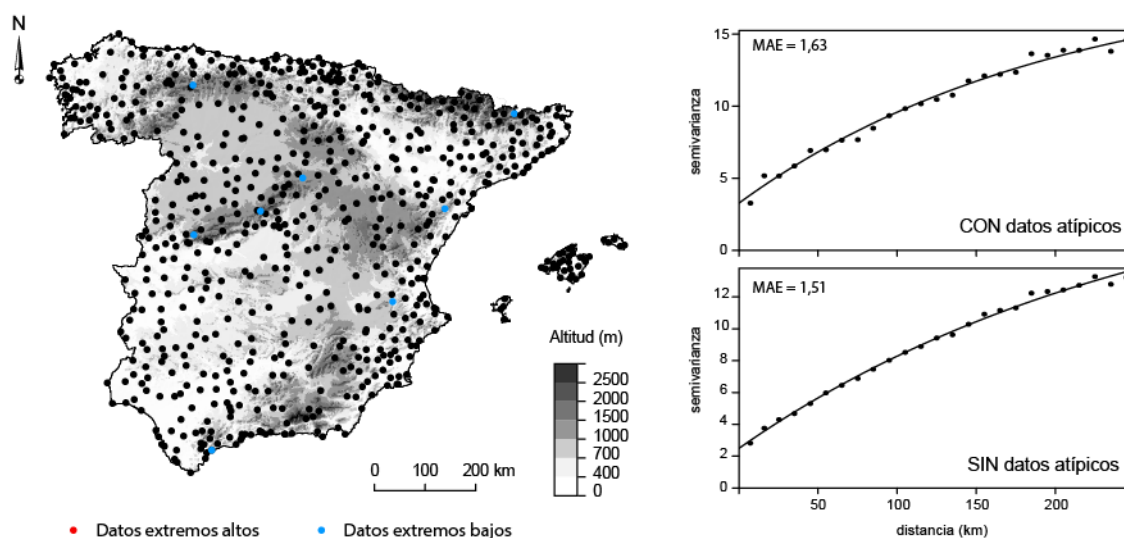


Figura 11. Ejemplo de localización de valores espaciales discordantes de temperatura máxima ($T_{máx}$) y los variogramas teóricos correspondientes ajustados con y sin estos valores. MAE, error absoluto medio obtenido de una validación cruzada con el método de *kriging* ordinario.

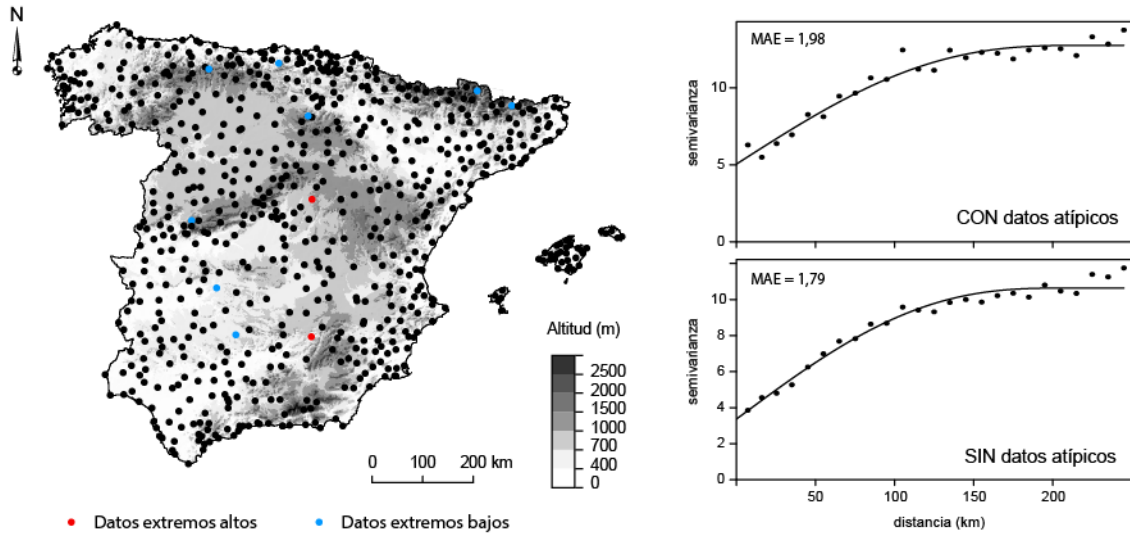


Figura 12. Ejemplo de localización de valores espaciales discordantes de temperatura en el punto de rocío (T_{pr}) y los variogramas teóricos correspondientes ajustados con y sin estos valores. MAE, error absoluto medio obtenido de una validación cruzada con el método de *kriging* ordinario.

4.3. Métodos de interpolación

4.3.1. Regresión lineal

Los resultados del modelo RL1 (Ec.11) fueron claramente inválidos para la $T_{máx}$ (consultar el Anexo 1 para ver los resultados de la regresión lineal). El análisis de los residuos desveló el incumplimiento de los supuestos de linealidad y normalidad. Se observó una parábola asociada a la falta de linealidad en la comparación con los valores estimados, además de un sesgo negativo común en el periodo de estudio. También, se detectaron puntos influyentes que ejercían una atribución significativa en el ajuste del modelo. Estos puntos coincidían parcialmente con localizaciones extraídas en el ajuste del variograma teórico (*valores atípicos espaciales*).

Por el contrario, el modelo RL2 (Ec.12) mostró buenos resultados en el análisis de los residuos, salvo días puntuales donde se detectó una leve tendencia a la no linealidad. Los p -valores de las pruebas F (Fisher) y t (Student) certificaron la validez del modelo general y de sus coeficientes ($p < 0,05$), a excepción de algunos casos en los que algún parámetro (principalmente la *longitud* o la *longitud*²) no fue estadísticamente diferente de 0.

En cuanto a la T_{pr} , ambas funciones (RL1 y RL2) manifestaron un comportamiento parecido entre ellas. El coeficiente asociado a la *elevación* fue significativo en todos los casos ($p < 0,05$). Por otro lado, la trascendencia de la *longitud* en el modelo RL1 fue marginal en varias ocasiones ($p > 0,05$); en el modelo RL2 fue más común que esto ocurriera con los parámetros *longitud*, *longitud*² y, en ciertos casos, la *latitud*.

De forma general, el rendimiento de los modelos RL1 y RL2 fue mejor para la $T_{m\acute{a}x}$ (Tabla 5, pág.38). En comparación, el error de los residuos (SD_{resid}) de RL2 en la T_{pr} se mostró inferior al de RL1 (promedio de 2,81 °C frente a 3,03 °C). De igual modo, los valores de AIC fueron más bajos para este modelo (diferencia media de 103 puntos).

Adicionalmente, se examinó la correlación lineal entre las variables auxiliares y las variables de interés. En general, los gráficos de las Figuras 13 y 14 muestran valores de correlación bajos o moderadamente bajos, como es el caso de la *latitud* para la $T_{m\acute{a}x}$ o la *elevación* para la T_{pr} .

Se observó que los diagramas de dispersión (no se muestran aquí) de la variable *longitud* dibujaban a menudo una nube de puntos sin aparente relación con ninguna de las variables. Si bien, en ciertas ocasiones, esta trazaba una parábola que sugería una tendencia decreciente con la proximidad al mar (a longitudes extremas menor temperatura).




Figura 13. Valores del coeficiente de correlación de Pearson entre la temperatura máxima ($T_{m\acute{a}x}$) y las variables auxiliares *elevación* (A), *latitud* (B) y *longitud* (C). La línea roja marca el valor promedio obtenido en el periodo de estudio. Los puntos por encima de la línea de unión de los valores (línea negra) indican que no son estadísticamente distintos de 0, con un nivel de confianza del 95%.




Figura 14. Valores del coeficiente de correlación de Pearson entre la temperatura del punto de rocío (T_{pr}) y las variables auxiliares *elevación* (A), *latitud* (B) y *longitud* (C). La línea roja marca el valor promedio obtenido en el periodo de estudio. Los puntos por encima de la línea de unión de los valores (línea negra) indican que no son estadísticamente distintos de 0, con un nivel de confianza del 95%.

4.3.2. Validación y comparación de los métodos

El rendimiento de las técnicas de interpolación estudiadas se resume en la Tabla 5 y los resultados numéricos de la validación se pueden consultar en el Anexo 4. Para automatizar el proceso, el radio de influencia para la implementación de los métodos basados en distancias se fijó en la longitud que marcaba el rango efectivo del modelo de semivarianza, o en 250 km si este era mayor que la distancia de observación del variograma.

El MBE fue cercano a 0 en todos los métodos, lo cual indica que las estimaciones de $T_{máx}$ y T_{pr} no mostraban ningún sesgo significativo.

La técnica de OK mostró una precisión superior en las estimaciones de ambas variables, aunque con escasas diferencias al método de IDW. Los peores resultados fueron para los modelos de regresión lineal RL1 y RL2, en este orden. En general, los valores de MAE no se alejaron mucho de los valores de la RMSE, lo cual apunta a una escasa presencia de errores relativamente altos en las estimaciones. En términos relativos (relación MAE/media), los errores obtenidos fueron, en conjunto, inferiores al 9% para la $T_{máx}$ e inferiores al 19% para la T_{pr} .

Evalrados temporalmente, los errores en la T_{pr} mostraron una predisposición a aumentar con el paso de los días (Figura 16) contraria a la estabilidad manifestada en los gráficos de la $T_{máx}$ (Figura 15); los valores máximos de error para la T_{pr} se alcanzaron al final del periodo de estudio. Esto coincide, de nuevo, con el aumento de la varianza en la T_{pr} del mes de julio con

respecto a la del mes anterior. Cabe destacar la similitud de los resultados entre métodos (o incluso mejores en el caso de la $T_{m\acute{a}x}$) en el inicio del periodo de estudio (del 1 al 13 de junio). Este hecho parece estar asociado a correlaciones altas de las variables objetivo con las variables auxiliares *elevación* y *longitud* analizadas conjuntamente (ver Figuras 13 y 14, pág.36).

En conjunto, la capacidad explicativa de los distintos métodos fue menor para la T_{pr} . Nuevamente, el método de OK mostró mejor rendimiento que los demás; explicó, en promedio, el 78,6% de la variación de los datos de la $T_{m\acute{a}x}$ y el 66% en T_{pr} , con un comportamiento muy parecido a IDW en los dos casos y durante todo el periodo de estudio. Ambos métodos fueron considerablemente más estables que los modelos de regresión (RL1 y RL2). En la $T_{m\acute{a}x}$, se hizo evidente el mal funcionamiento del modelo RL1, con valores de R^2 en torno a 0,2 y muy por debajo de los otros métodos (Figura 15).

Como dato informativo, el coeficiente de ponderación de la distancia en el método IDW osciló entre el 2,5 y el 3,6, con un valor promedio de 3,1 en la $T_{m\acute{a}x}$, y entre el 2,3 y el 3,3, con un valor promedio de 2,8 en la T_{pr} .

Tabla 5. Error absoluto medio (MAE), raíz del error cuadrático medio (RMSE), error medio (MBE) y coeficiente de determinación (R^2) de los distintos métodos de interpolación. Valores promedio para la temperatura máxima ($T_{m\acute{a}x}$) y la temperatura en el punto de rocío (T_{pr}) en el periodo de estudio.

Método	Tmáx (°C)					Tpr (°C)				
	MAE	MAE/m ^b	RMSE	MBE	R^{2a}	MAE	MAE/m	RMSE	MBE	R^2
RL1	2,347	0,086	2,931	-1,5e-17	0,476	2,313	0,185	3,027	6,9e-18	0,450
RL2	1,917	0,070	2,417	8,3e-19	0,647	2,120	0,170	2,803	4,5e-18	0,523
IDW	1,476	0,054	1,905	0,061	0,767	1,757	0,141	2,342	-0,036	0,630
OK	1,402	0,051	1,819	-0,003	0,786	1,674	0,134	2,224	-0,010	0,663

^a valor adimensional.

^b m, media aritmética de los valores observados en el periodo de estudio.




Figura 15. Valores diarios del error absoluto medio (MAE), raíz del error cuadrático medio (RMSE) y coeficiente de determinación (R^2) calculados a partir de las estimaciones de la temperatura máxima ($T_{máx}$) realizadas con los distintos métodos de interpolación.




Figura 16. Valores diarios del error absoluto medio (MAE), raíz del error cuadrático medio (RMSE) y coeficiente de determinación (R^2) calculados a partir de las estimaciones de temperatura del punto de rocío (T_{pr}) realizadas con los distintos métodos de interpolación.

La Tabla 6 muestra las estimaciones del error absoluto medio (MAE) para el déficit de presión de vapor (D) y la humedad de los combustibles finos muertos (FM). Se observó que, con el aumento de la $T_{m\acute{a}x}$, el error de estimación incrementaba en D y disminuía en la FM , mientras que, con el aumento de la T_{pr} el error fue creciente en ambos casos. Estos resultados se justifican a través de los gráficos de la Figura 17. Una misma diferencia en la $T_{m\acute{a}x}$ provoca mayores cambios en D (mayor pendiente en la relación) cuando esta es alta. Por otro lado, cuando la $T_{m\acute{a}x}$ es alta, el D es más alto y los cambios en la FM son más suaves (menor pendiente). En el caso de la T_{pr} , cuando esta es elevada, la humedad relativa (HR) tiende a ser también elevada. A mayor HR , la magnitud de D es menor y los cambios son más pequeños. En este caso, pequeños cambios en el D influyen más en la FM .

Comparando los métodos, la tendencia fue la misma a la encontrada hasta ahora; la técnica de OK ofreció los mejores resultados. Centrándonos en la FM , el error relativo al valor estimado en el percentil 50 fue del 5,4% y del 4,8% para la $T_{m\acute{a}x}$ y la T_{pr} , respectivamente. En el lado opuesto se situó el modelo RL1, cuyos mismos valores fueron de 9,0% y 6,6%.

Tabla 6. Estimaciones del error absoluto medio (MAE) para el déficit de presión de vapor (D) y la humedad de los combustibles finos muertos (FM).

	Estimado		MAE _D (kPa)				MAE _{FM} (%)			
	D (kPa)	FM (%)	RL1	RL2	IDW	OK	RL1	RL2	IDW	OK
$T_{m\acute{a}x}50^{ab}$	2,22	9,46	0,305	0,249	0,192	0,182	0,853	0,697	0,536	0,509
$T_{m\acute{a}x}95^{ab}$	3,76	7,32	0,495	0,404	0,311	0,296	0,279	0,227	0,174	0,165
$T_{pr}50^c$	2,25	9,38	0,223	0,204	0,169	0,163	0,622	0,567	0,467	0,448
$T_{pr}95^c$	1,32	13,64	0,316	0,289	0,240	0,230	2,366	2,153	1,766	1,692

^a Percentil 50 y percentil 95 del promedio de los valores observados.

^b Errores calculados a partir del valor de temperatura máxima ($T_{m\acute{a}x}$) observado y su valor correspondiente de humedad relativa mínima.

^c Errores calculados a partir del valor de temperatura en el punto de rocío (T_{pr}) observado y su valor correspondiente de $T_{m\acute{a}x}$.




Figura 17. Ejemplo de relaciones entre el déficit de presión de vapor (D), la humedad de los combustibles finos muertos (FM), la humedad relativa mínima (HR), la temperatura máxima ($T_{m\acute{a}x}$) y la temperatura en el punto de rocío (T_{pr}).

4.4. Mapas

4.4.1. Interpolaciones y humedad de los combustibles

Como ejemplo ilustrativo, se exponen a continuación los mapas interpolados de $T_{m\acute{a}x}$ y T_{pr} correspondientes al día 25 de julio, cuyos valores de error y R^2 fueron representativos de lo anteriormente descrito. Se añaden, también, los mapas derivados de D y FM para el mismo día y según cada método de interpolación.

La resolución empleada proporcionó un nivel de detalle adecuado, a la vez que un peso razonable del archivo en términos de memoria computacional.

Los mapas de $T_{m\acute{a}x}$ (Figura 18) generados con los métodos de OK y IDW mostraron una buena relación con los registros observados de ese mismo día y un comportamiento muy parecido entre ellos. Uno y otro ofrecieron valores de R^2 de 0,79 y 0,76, respectivamente. En los modelos de regresión, estos valores fueron de 0,53 (RL2) y 0,31 (RL1). Quedó en evidencia el mal comportamiento ya descrito (apartado 4.3.1) del modelo RL1.

En cuanto a la T_{pr} (Figura 19), el resultado fue muy similar al anterior. Los valores de R^2 fueron de 0,75 (OK), 0,71 (IDW), 0,58 (RL2) y 0,47 (RL1). En este caso, los modelos de regresión fueron más semejantes entre ellos. No obstante, ambos mapas exhiben una tendencia a predecir valores superiores a los observados en determinadas zonas.

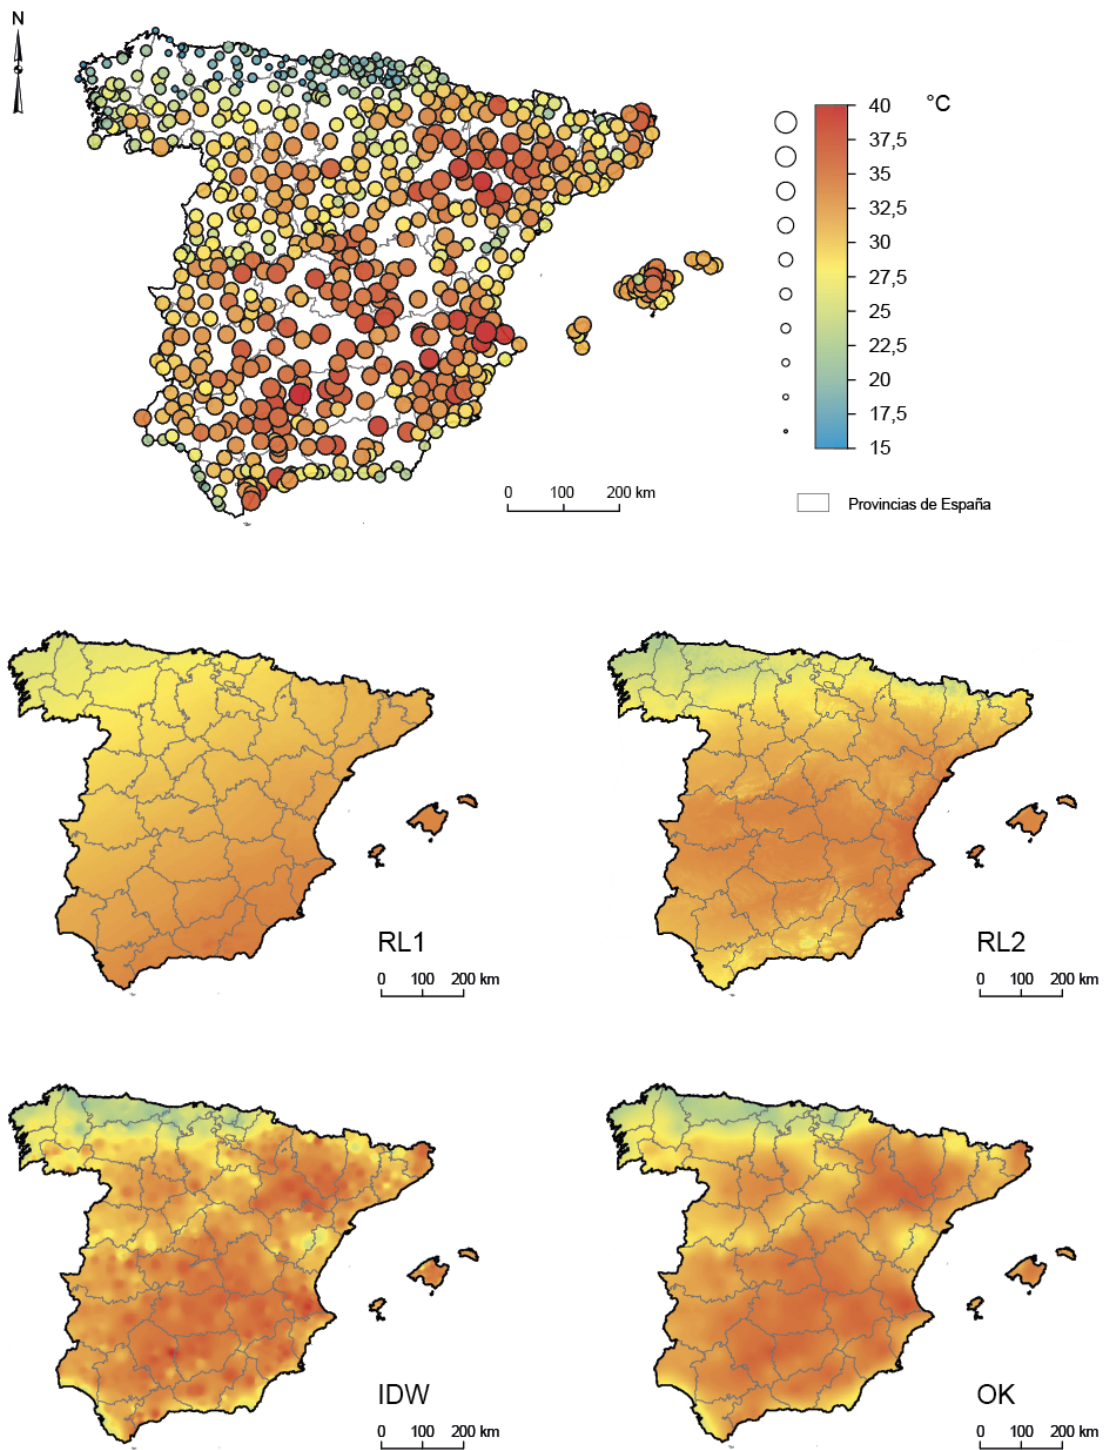


Figura 18. Mapas de temperatura máxima ($T_{m\acute{a}x}$) del d\`ia 25 de julio de 2018. El mapa superior muestra los valores observados; el resto son los mapas interpolados con regresi3n lineal 1 (RL1), regresi3n lineal 2 (RL2), ponderaci3n por el inverso de la distancia (IDW) y *kriging* ordinario (OK).

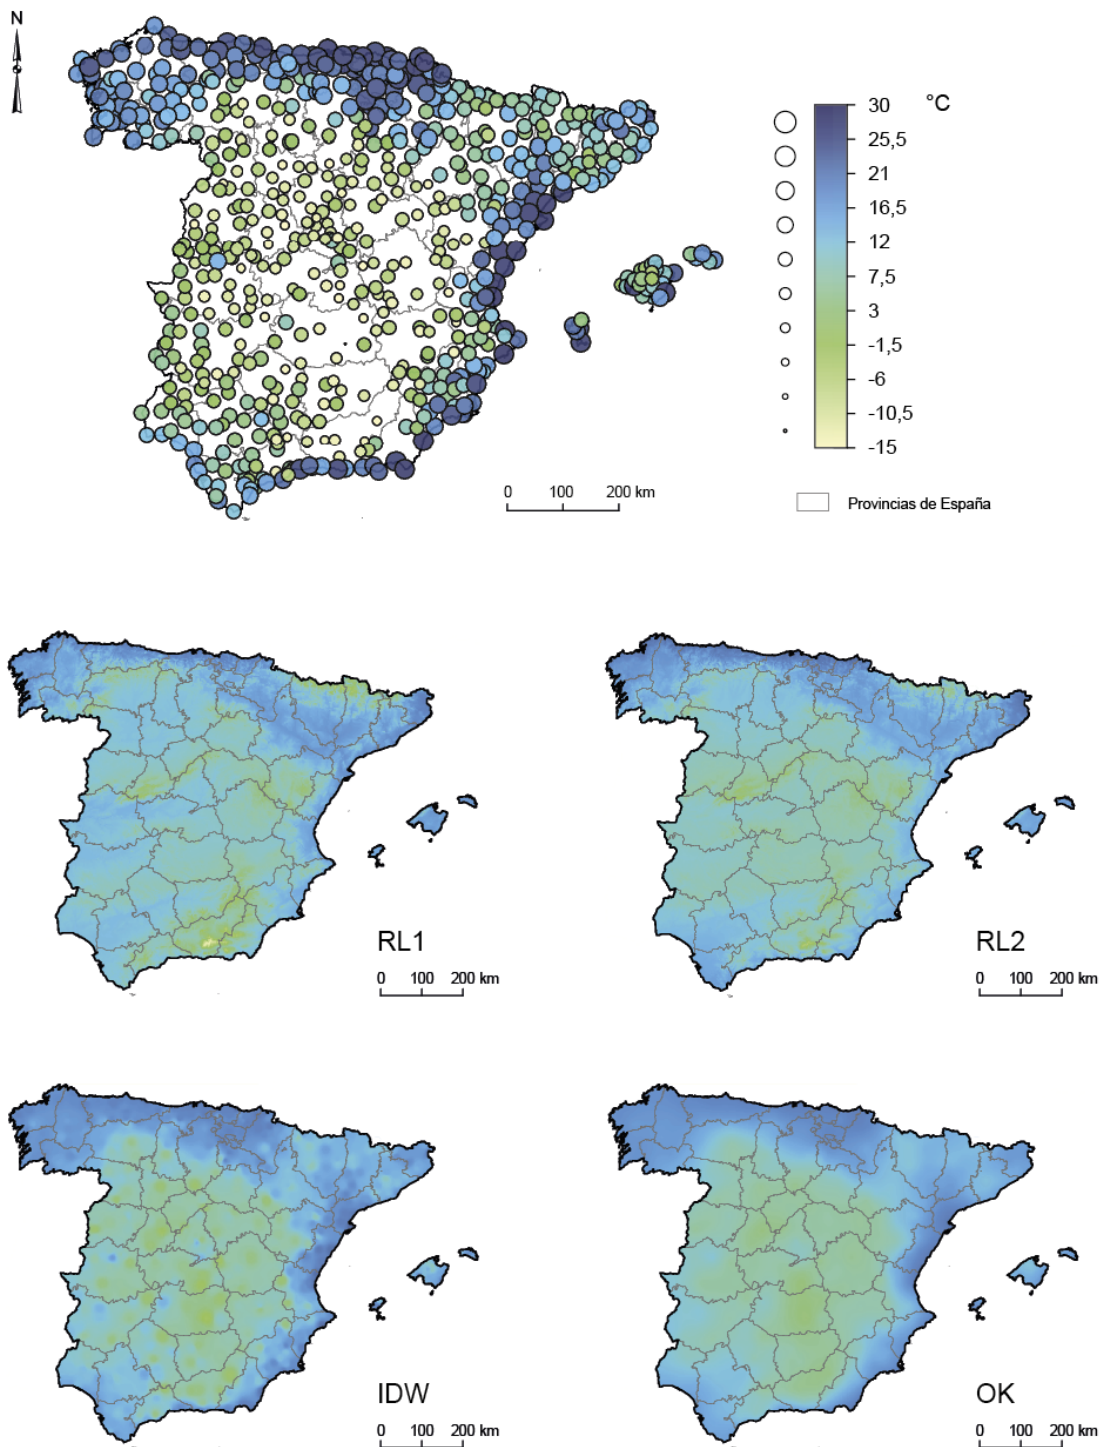


Figura 19. Mapas de temperatura del punto de rocío (T_{pr}) del día 25 de julio de 2018. El mapa superior muestra los valores observados; el resto son los mapas interpolados con regresión lineal 1 (RL1), regresión lineal 2 (RL2), ponderación por el inverso de la distancia (IDW) y *kriging* ordinario (OK).

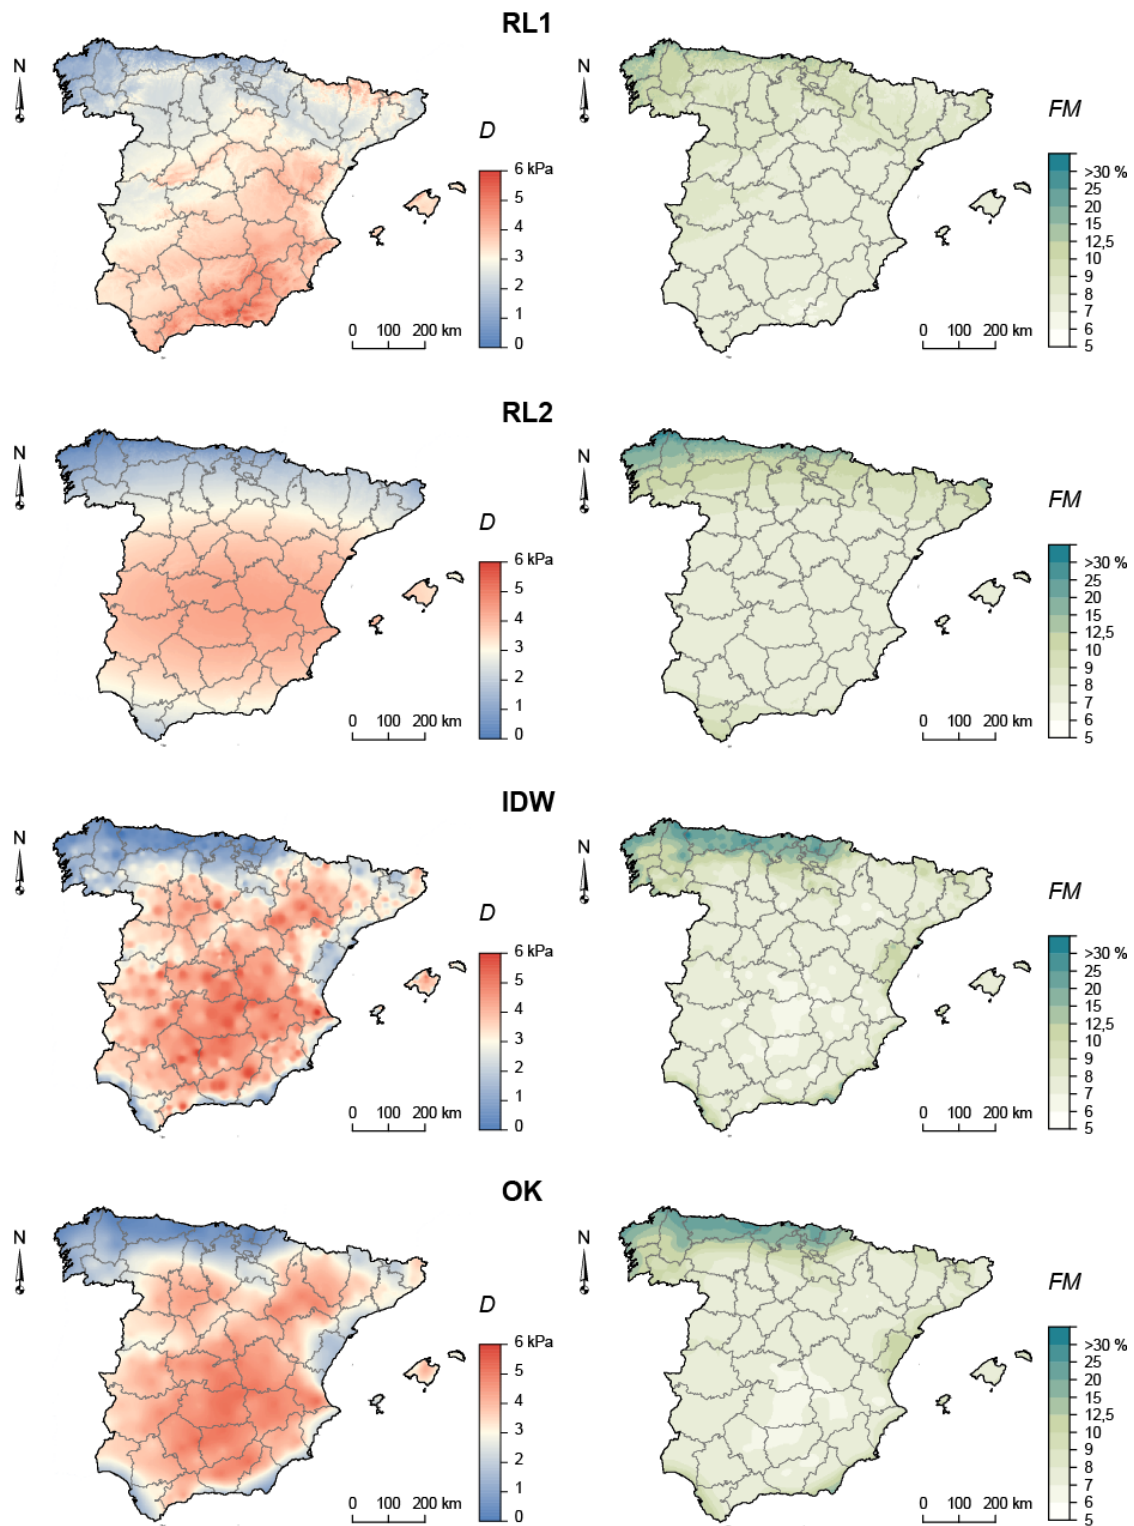


Figura 20. Mapas de déficit de presión de vapor (D ; izquierda) y humedad de los combustibles finos muertos (FM ; derecha) del día 25 de julio de 2018. RL1, regresión lineal 1; RL2, regresión lineal 2; IDW, ponderación por el inverso de la distancia; OK, *kriging* ordinario.

Las semejanzas entre los mapas interpolados con IDW y OK resultan visibles también en los mapas de D y FM (Figura 20). No obstante, OK crea superficies suavizadas y continuas mientras que, con el método IDW se generan mapas menos estéticos, con máximos y mínimos a modo de manchas que se corresponden con las ubicaciones de los puntos de muestreo.

4.4.2. Mapas de disponibilidad de los combustibles

La Figura 21 representa las predicciones de humedad (FM) y los mapas derivados de los umbrales críticos de FM en un lapso de 5 días. Con estos mapas se pretende enseñar cómo el modelo de FM (Ec.1) proyecta los cambios a gran escala producidos en un periodo de tiempo muy corto, acorde con lo explicado en el inicio de este trabajo.

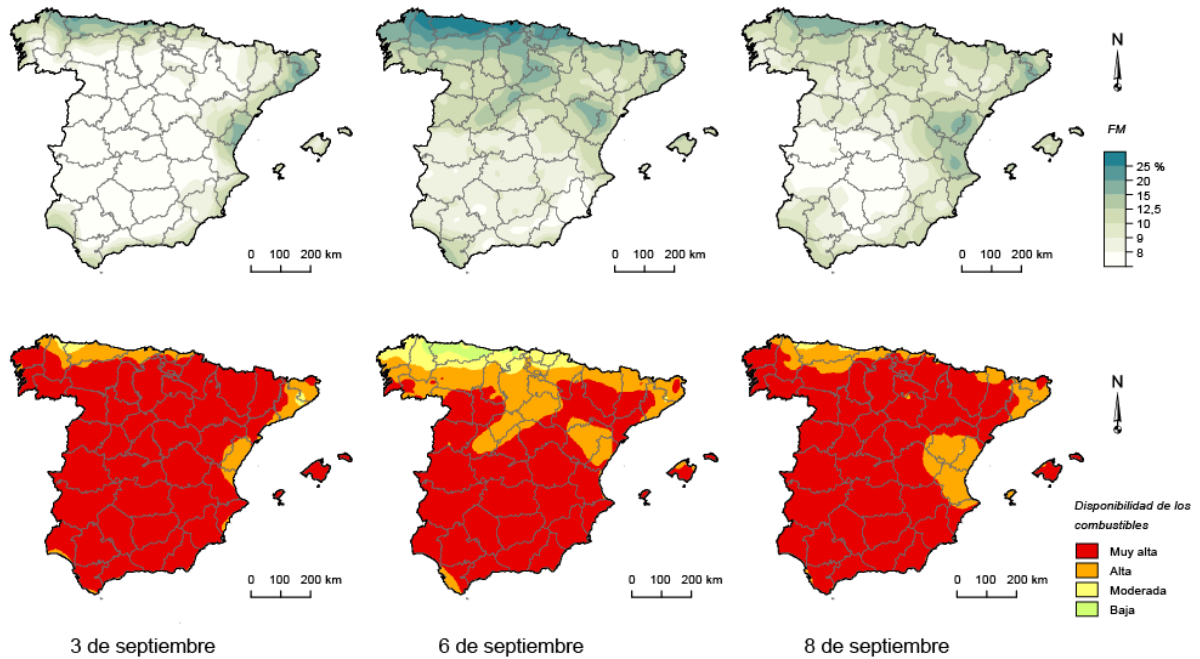


Figura 21. Mapas de humedad y de disponibilidad de los combustibles finos muertos de días aleatorios en el periodo del 3 al 8 de septiembre.

5. Discusión de los resultados

5.1. Análisis preliminar de los datos

Varios estudios (Li y Heap, 2014) afirman que la normalidad de los datos puede influir significativamente en el rendimiento de determinados métodos de interpolación, siendo estos más eficientes cuando se aplican en variables que presentan una distribución normal o Gaussiana (Cressie, 1993; Webster y Oliver, 2007; J. Wu, Norvell, y Welch, 2006).

En nuestro caso, la interpretación integral de las medidas descriptivas no indicó claramente que el proceso que forma el conjunto de los datos estuviese distribuido como una normal.

Según J. Wu et al., (2006), la transformación de los datos puede ser deseable para normalizar su distribución, además de suprimir los valores atípicos y mejorar la estacionariedad. Sin embargo, no hubo motivos para diagnosticar que los datos estuvieran sesgados ni que existieran valores extremos que afectaran a la distribución, y la aplicación de las principales transformaciones (Cressie, 1993) no mejoró los resultados.

Por otro lado, la ligera tendencia a distribuciones platicúrticas de la T_{pr} y la existencia de dos máximos en los gráficos de densidad de probabilidad de ambas variables informó de la presencia de, por lo menos, dos poblaciones distintas en la región de estudio. Esta circunstancia implica la violación de la primera parte de la hipótesis de estacionariedad (Ec.8, $E[Z(s)]$ constante en toda la región) en la cual se basan los métodos de interpolación fundados en la geoestadística. Es probable que estas poblaciones estén asociadas a las distintas regiones bioclimáticas que ocupan el territorio (Olson et al., 2001). Su inclusión en futuros trabajos con el fin de estratificar los datos en sus distintas estructuras puede ser un factor que considerar para mejorar la precisión de las estimaciones de FM .

La variación y la amplitud de los datos también influye en el funcionamiento de los métodos de interpolación y a los resultados de las predicciones (Li y Heap, 2014). En la T_{pr} , se pudo comprobar como el incremento de ambos en el mes de julio afectó negativamente al rendimiento de los métodos de interpolación. Estos factores son el reflejo de la heterogeneidad de la superficie de estudio y de la variable observada (Li y Heap, 2011), por este motivo, es importante disponer de una buena cantidad de puntos de muestreo y que estos estén bien distribuidos en el área de estudio.

Durante todo el periodo de estudio, el número de estaciones meteorológicas fue totalmente satisfactorio. Se cumplía ampliamente el mínimo aconsejado por Webster y Oliver (2007) de 150 puntos de muestreo para una estimación aceptable del variograma muestral.

Por otra parte, el análisis de patrones de puntos sugirió un patrón de distribución ligeramente regular pero homogéneamente distribuido al azar por toda el área de estudio. Según Li y Heap (2014), la distribución regular de los puntos de muestreo favorece el funcionamiento del método de IDW y reduce las diferencias en los resultados obtenidos con el método de OK. No obstante, el abanico de distancias que los separaban fue apropiado para capturar los cambios en las distintas escalas de variación y, aunque la distribución observada en la función de vecindad (*funcion G*) se encontraba fuera de los límites del intervalo de confianza de la función teórica, se dedujo que la distribución de puntos era representativa del área de estudio.

Al mismo tiempo, las elevaciones estuvieron bien representadas en su conjunto. La débil presencia de registros por encima de los 1200 metros no debe suponer un problema grave para el propósito de la interpolación. Las temperaturas más altas se registran en zonas de menor altitud y del interior peninsular (AEMET-IM, 2011) donde se esperan los valores más bajos de *FM* durante el verano, y donde ya existe una buena representación de estaciones (Figura 8, pág.30).

5.2. Relaciones espaciales

5.2.1. Autocorrelación, estacionariedad e isotropía

Ambas variables mostraron estar autocorrelacionadas espacialmente. A su vez, el aumento brusco de la varianza después de alcanzar un máximo, se interpreta (Webster y Oliver, 2007) como un signo de tendencias en la variación a escala regional (distancias largas) superpuestas a la variación aleatoria a escala local (distancias cortas). Esto confirmaba la existencia de estructuras diferenciales en el espacio de estudio, incumpliendo de nuevo la condición de estacionariedad (la $E[Z(s)]$ dependía de la posición).

Por otra parte, aunque los variogramas direccionales no manifestaron un claro comportamiento anisotrópico por diferencias en la continuidad espacial (anisotropía geométrica), las diferencias claras de varianza entre los variogramas de longitud (este-oeste) frente al resto sugerían una pauta distinta de las variables de interés dependiente de la dirección. Este tipo de anisotropía (anisotropía zonal) se atribuye, de nuevo, a la presencia de estructuras distintas en la región de estudio (Webster y Oliver, 2007).

Estas circunstancias llevaron a adoptar un enfoque más localizado, donde se asumía estacionariedad a nivel local y la anisotropía no parecía tan evidente dentro de la zona de influencia reducida. Según Li y Heap (2014), cuando esto ocurre, la anisotropía puede ser ignorada para simplificar el ajuste del modelo de semivarianza. Por otro lado, Haberlandt (2007) no encontró diferencias significantes en las predicciones de *kriging* entre los variogramas isotrópicos y los anisotrópicos, aunque la anisotropía estuviese claramente presente en los datos.

5.2.2. Modelización de la variación espacial

La variabilidad de los parámetros de los variogramas teóricos ajustados a diario puso en evidencia el dinamismo a corto plazo de los fenómenos explicados. Generalizar un modelo de varianza para toda la temporada de incendios puede derivar en resultados poco efectivos y confiables de las estimaciones en algunas secuencias de tiempo. Con la automatización del proceso se pretende evitar este problema ajustando los variogramas continuamente a cada conjunto de observaciones diarias.

El mayor uso de funciones no acotadas superiormente, como en este caso la exponencial, o los valores de rango superiores a la distancia reducida indican que el fenómeno explicado se extiende más allá de los límites de estudio (Olaya, 2014). No obstante, la previsión de usar métodos de interpolación localizados dota de mayor importancia que el variograma teórico sea más preciso en la parte inicial, sin importar qué ocurre fuera de la ventana de observación.

Bajo esta premisa, los variogramas de la $T_{máx}$ exhibieron muy buenos resultados. El comportamiento inicial lineal corresponde al de una variable continua, mientras que la baja varianza a distancia 0 (*efecto nugget*) indica que la semejanza entre dos datos muy cercanos es baja, con lo cual, los modelos ajustados tienden a explicar gran parte de la variación espacial del fenómeno.

En cuanto a la T_{pr} , sus resultados fueron menos satisfactorios. En varias ocasiones, el *efecto nugget* representó un porcentaje considerable de la varianza estructural que no podemos explicar. En este caso, la semejanza entre dos datos muy cercanos no es despreciable, hecho que se confirma con el registrado de varianzas mayores en el primer intervalo. Según Hengl (2009), esta mayor diferencia en el intervalo inicial se asigna a un comportamiento distinto de la variable a pequeña escala que no se recoge bien al nivel de precisión de trabajo.

En resumen, la automatización del proceso es una solución práctica para realizar el ajuste diario de los variogramas. En un estudio parecido, Haberlandt (2007) obtuvo los mejores resultados de esta manera. No obstante, se debe tener en cuenta que, a veces, el ajuste automático puede no converger en una solución razonable difícil de controlar.

5.2.3. Valores atípicos espaciales

La proporción de valores topológicamente incoherentes fue relativamente baja. No obstante, su extracción tuvo efectos positivos en el ajuste de los variogramas (reducción de la varianza no espacial y mejora de la precisión del modelo en distancias cortas) y en el rendimiento común de los métodos de interpolación basados en distancias (reducción del error de estimación). No obstante, cabe destacar que un dato atípico no es forzosamente falso. Acorde con Lu et al. (2003), este podría reflejar el comportamiento verdadero de la variable regionalizada y eliminarlo impediría prever la ocurrencia de tales valores en las zonas no muestreadas.

Desde un punto de vista teórico (Ec.1-4), el tipo (valores bajos) y la localización (zonas altas de montaña) de los valores atípicos de la $T_{máx}$ justificaba su extracción; valores bajos de $T_{máx}$

equivalen a valores bajos de D (Figura 17D, pág.41) y, por consiguiente, a valores altos de FM . Así pues, el suavizado de la superficie interpolada en esas zonas por la generalización del fenómeno puede procurar un enfoque preventivo más seguro a la ocurrencia de incendios, no obstante, también podría devenir en alertas mayores a las reales que generen problemas en la movilización de recursos.

En cuanto a la T_{pr} , las consecuencias de la eliminación de estos datos no siempre fueron tan evidentes. La relación de la humedad relativa (HR) con D es clara (Figura 17F); a menos HR mayor es D . No obstante, no ocurre lo mismo con la T_{pr} ; aunque la relación con D parecía ser negativa (Figura 17E), la dispersión de los valores no la hacía nada evidente en la mayoría de las ocasiones. Esto se debe a que la T_{pr} depende de la presión parcial de vapor de agua (e_a), que al mismo tiempo depende de la temperatura del aire y de su contenido de humedad (Wallace y Hobbs, 2006).

5.3. Rendimiento de los métodos de interpolación

Los métodos de interpolación basados en distancias funcionaron mejor que los modelos de regresión lineal. El rendimiento de estos últimos depende mucho del tipo y grado de correlación existente con las variables predictoras (Li y Heap, 2014) que, por lo general, fue bajo. La razón de esta falta de correlación podría atribuirse a la complejidad del territorio, donde existen muchos otros factores que ejercen influencia sobre la temperatura y la humedad. La inversión marina en localizaciones costeras (Daly et al., 2008) o la orientación y el ángulo de la pendiente en zonas montañosas además de la influencia directa de la elevación (Benavides et al., 2007; Stahl, Moore, Floyer, Asplin, y McKendry, 2006) son algunos de los factores que no han sido considerados en este trabajo.

Por el contrario, el método geoestadístico de OK con enfoque localizado fue el más efectivo y exacto de la comparación. Acorde con las formas de los variogramas, se consideró adecuada la reducción del radio de influencia de puntos a distancias iguales o inferiores a los 250 km. Según Beek (1991), el comportamiento a media escala de las variables meteorológicas no difiere mucho en un rango de 50-150 km. Además, esta reducción supone utilizar un promedio de 275 puntos para hacer la predicción en un punto desconocido; 68 si lo reducimos a un solo cuadrante por el efecto borde de los límites de estudio. Es una cantidad suficiente si consideramos que, sin una proporción muy elevada del *nugget*, los cuatro o cinco puntos más cercanos pueden contribuir con aproximadamente el 80% del peso total de ponderación (Webster y Oliver, 2007).

No fue nada extraño que todos los métodos mostraran menor capacidad explicativa en predecir la T_{pr} . Su estructura espacial fue menos regular y con mayor variación a pequeña escala que la de la $T_{máx}$. A pesar de ello, el error estimado sobre el déficit de presión de vapor (D) y la humedad de los combustibles finos muertos (FM) fue relativamente bajo en ambos casos. Su comportamiento fue totalmente lógico y favorable a los umbrales de riesgo; la exactitud de las estimaciones se predijo mayor cuando las condiciones de temperatura y humedad relativa eran peores. Esto coincide con los resultados obtenidos por Resco de Dios et

al. (2015), que demuestran que el modelo de predicción de la humedad funciona mejor en el rango de FM más crítico para la ocurrencia de grandes incendios.

6. Aplicación funcional

El trabajo aquí realizado sirve para hacer operativo el modelo FM_D (Ec.1) a escala regional. Una vez desarrollado el código que permite obtener los mapas de humedad se busca la realización de una página web en la que, de forma automatizada, se actualice el valor de FM diariamente en todo el territorio español. Esto valdrá para disponer de una alerta temprana frente a situaciones de probabilidad extrema de gran incendio forestal (GIF) y poder, así, movilizar a los operativos del dispositivo de extinción de forma anticipada y restringir el acceso o las actividades en el monte durante una situación excepcional.

Se ha demostrado que el sistema actual de probabilidad de incendios presenta grandes carencias. Por ejemplo, en el incendio de Pedrogão Grande, el índice FWI no predijo la situación de peligro extremo que realmente se vivió, mientras que, FM_D sí que anotó valores fuera del rango histórico de la temporada de incendios (Boer et al. 2017). Este trabajo permite, por tanto, una mejora notable a la forma que existe actualmente de calcular la probabilidad de ocurrencia de un GIF.

A continuación, se describe el uso previsto de los mapas de humedad y la operatividad y necesidad de esta aplicación, así como, las limitaciones y mejoras propuestas para su completa funcionalidad.

6.1. Aplicación y uso de los mapas

Los mapas creados con el método de *kriging* (OK), además de ser más precisos y representativos que los demás, fueron preferidos desde un punto de vista estético. La continuidad que presentaron las superficies generadas parecía más acorde a lo que puede ocurrir en la realidad de los fenómenos atmosféricos.

Estos mapas proporcionan, de una manera relativamente simple, la humedad de los combustibles finos muertos (FM) en todo el territorio con el principal fin de ayudar en las actuaciones de coordinación, prevención y extinción de incendios forestales. No obstante, aunque el enfoque de este trabajo es el de aplicar el modelo FM_D (Ec.1) a un índice discreto de alerta temprana del riesgo de incendios, FM es requerido en muchos otros campos, tales como la hidrología forestal o la ecología. Por ejemplo, FM se usa para estudiar la dinámica del agua en las capas de hojarasca del suelo o los flujos atmosféricos en zonas forestales (Matthews, 2013). Los mapas aquí generados proporcionan predicciones directas de este factor únicamente con datos de temperatura y humedad relativa, además de las estimaciones regionalizadas del déficit de presión de vapor (D) generadas en el proceso de cálculo, con una resolución moderada de 2,5 km x 2,5 km, que también pueden ser demandadas en este tipo de estudios.

Por otro lado, es preciso decir que el empleo de los niveles críticos de disponibilidad de los combustibles finos muertos no puede ser considerado por sí solo como un índice de riesgo meteorológico de incendio, sino como una condición asociado a la ocurrencia de GIF. Puede ocurrir que, si los combustibles vivos no se encuentran por debajo de sus umbrales de humedad, el fuego no se sustente. Bajo este concepto, Chuvieco, Aguado, y Dimitrakopoulos (2004) proponen un índice cuantitativo de riesgo de ignición basado en el contenido de humedad del combustible que podría ser estimado, en el caso de los combustibles muertos, a partir de los mapas de *FM* disponibles en la web. Este índice, que determinaría la probabilidad de ignición y propagación inicial del fuego, se podría combinar con otras variables de riesgo, como la pendiente, el viento o la carga de combustible, para crear un sistema completo de predicción del peligro de incendio para toda la zona mediterránea. De esta forma se integrarían los factores dinámicos a mediano y corto plazo que controlan la ocurrencia de incendios, y otras variables de carácter constante o a largo plazo como son el clima, los usos de la tierra, la estructura de la vegetación y la topografía.

6.2. Operatividad y necesidad de la aplicación

La gestión del territorio, en sus diferentes niveles, necesita conocer la probabilidad de que un incendio ocurra en un lugar y momento determinado con cierta precisión. La publicación diaria de mapas de humedad del combustible fino muerto pretende cubrir esta necesidad permitiendo a los organismos de gestión y control de incendios forestales conocer, a tiempo casi real, el riesgo de que tengan lugar este tipo de incendios.

Como ya se ha comentado, esta información se espera difundir a través de una página web desde donde cualquier usuario podrá consultar y descargar, de forma gratuita, los mapas diarios de *FM* en formato ráster GeoTiff⁷, compatibles con los sistemas de información geográfica de uso actual. Asimismo, la acumulación histórica de datos, que también estará disponible en la página web, permitirá el estudio de la evolución de *FM* en un lugar determinado, lo cual será de nuevo necesario para saber qué zonas del territorio son meteorológicamente más propensas a sufrir un GIF y actuar en consecuencia sobre los factores subyacentes de riesgo de incendio mediante los planes de gestión forestal, de prevención contra incendios, las actuaciones en perímetros de urbanizaciones o en otros tipos de gestión vinculadas al territorio.

Quizás la mejora más importante que presenta este trabajo es el desarrollo de una herramienta para predecir la humedad del combustible fino que ha sido pensada y validada principalmente para los ecosistemas mediterráneos. Actualmente usamos el modelo canadiense del FWI, desarrollado para las condiciones concretas de su territorio, y que resulta de escasa utilidad a nuestros servicios de extinción por su falta de precisión cuando se aplica fuera de la zona donde fue creado. *FM_D* ya es usado por los servicios de extinción de Nueva Gales del Sur, en Australia (NSW Rural Fire Service, 2018) y empieza a estar cada vez más extendido en la

⁷ El formato ráster GeoTiff es un tipo de archivo estándar que permite vincular información espacial georreferenciada dentro de un archivo de imagen con una resolución determinada.

literatura científica (Boer et al., 2017; Gray, Zachmann, y Dickson, 2018). Lo que aquí se busca es el desarrollo de un aplicativo que esté listo para ser usado también por los servicios de extinción españoles a nivel operativo como sustituto o complemento de los códigos de humedad de los actuales índices meteorológicos de peligro de incendio. En Cataluña, por ejemplo, se elabora un mapa de riesgo de incendio que considera todo tipo de factores asociados al fuego y utiliza FWI para la estimación de la humedad del combustible muerto. En este caso, FM_D supondría una mejora sustancial de estos mapas en términos de precisión además de una menor carga computacional, ya que el algoritmo del que depende es más sencillo y requiere de menos datos de entrada.

La anticipación a una situación de riesgo permite gestionar los recursos de forma más eficiente y reducir los costes asociados a la extinción si se actúa antes de que tenga lugar un GIF. Conocer los lugares propensos a sufrir situaciones extremas puede ayudar de forma significativa en la elaboración de planes de actuación o de evacuación para preservar la seguridad de los habitantes de zonas urbano-forestales.

En general, el coste que supone la implementación de este aplicativo es totalmente asumible ya que solamente requiere de un servidor que se conecte diariamente con el servicio de AEMET para la descarga de datos y el posterior cálculo de FM extendido a toda España. Adicionalmente, los códigos serían subidos a un repositorio libre para el uso y mejora por cualquier usuario con el fin de garantizar la evolución y expansión de esta aplicación.

6.3. Dificultades y soluciones previstas

Una de las limitaciones que presenta este método es que se obtienen valores diarios de FM de las últimas 24 horas, es decir, el estado que describen los mapas hace referencia al pasado. Desde el punto de vista de la prevención y para una mayor eficacia sería preciso que las situaciones de riesgo pudieran ser anticipadas antes de que ocurriesen. Si bien el uso de un modelo de predicción de las variables de entrada podría suponer una mejora notable al uso de esta herramienta aplicada a la predicción del riesgo de incendio, el hecho de disponer de los mapas históricos permite analizar, de forma indirecta, la tendencia que se intuye en la dinámica del tiempo atmosférico a corto plazo y los niveles normales adquiridos en años anteriores.

Por otro lado, no fue objeto de este trabajo evaluar si la cantidad de detalle representada por los mapas es la adecuada para el índice. Un problema del *kriging* es que puede suavizar demasiado la realidad (Hengl, 2009), sobre todo si lo comparamos con el detalle que puede ofrecer la regresión lineal, especialmente en terrenos complejos (Benavides et al., 2007). Ante esta objeción, los buenos resultados obtenidos con OK y el buen comportamiento del modelo polinómico RL2 podrían impulsar la aplicación de un modelo combinado más preciso, que proporcionara el detalle de la regresión y generara superficies graduales como las del *kriging*. T. Wu y Li (2013) obtuvieron mejores resultados que OK empleando la regresión lineal para modelizar las tendencias a gran escala y la técnica del *kriging* para explicar la variación espacial a pequeña escala. Con este enfoque se esperaría lograr mapas más exactos y con mayor

funcionalidad en otros campos, al mismo tiempo que no sería necesario adaptar los modelos de predicción a las distintas zonas climáticas que presenta el conjunto del territorio español. A pesar de todo ello, para evaluar qué tan reales son las predicciones de humedad, sería necesario compararlas con mediciones adquiridas sobre el terreno.

7. Conclusiones

En este proyecto se ha desarrollado un método que proporciona mapas del contenido de humedad de los combustibles finos muertos (*FM*) para el área comprendida por la Península Ibérica y las Islas Baleares.

Esto se ha conseguido poniendo en práctica un modelo semi-mecanicista simple, basado en la demanda evaporativa de la atmósfera y que requiere, únicamente, de registros de temperatura y humedad relativa.

Con estos mapas se ha podido estimar el riesgo meteorológico de ocurrencia de incendio en todo el territorio a través de un índice categórico de 4 niveles de disponibilidad de los combustibles finos muertos (muy alta, alta, moderada y baja), que relaciona el *FM* con el incremento de área quemada tras un incendio.

De las tres técnicas de interpolación empleadas para generar las superficies continuas a partir de los registros puntuales de las variables meteorológicas, la técnica de *kriging* ordinario (OK) mostró ser la más precisa y efectiva, con un error estimado de *FM* comparable al error que se puede cometer en su medición real.

Las tendencias encontradas a gran escala se resolvieron adoptando un enfoque localizado del método, donde se asumía el cumplimiento de los supuestos de estacionariedad e isotropía requeridos por el mismo en un entorno de influencia reducido.

La reducción del error de estimación resultó ser un criterio práctico para la automatización del proceso. La pérdida de información por la eliminación de datos espacialmente extraños pero posibles o por la reducción del entorno de observación fueron compromisos inevitables para mejorar las predicciones sin necesidad de asistir los ajustes.

Una vez probados los métodos más utilizados en la literatura, el siguiente reto se debe centrar en estudiar cómo influyen las decisiones tomadas validando los mapas con mediciones reales sobre el terreno, y en la posibilidad de crear un método combinado más preciso cuya aplicación no complique la automatización del proceso. El uso del modelo de regresión lineal RL2, para modelizar las tendencias detectadas a escala regional, y la técnica de OK, para estudiar las relaciones espaciales a nivel local, serían la propuesta para este fin.

Al mismo tiempo, se propone ajustar los umbrales críticos de humedad de los combustibles muertos a nuestro territorio, teniendo en cuenta los principales climas del país, y aplicar el mismo procedimiento al resto de zonas con posibilidad de sufrir un incendio forestal; las Islas Canarias.

Todo ello deberá ser culminado con la difusión de la información de manera pública mediante un aplicativo web donde, además de los mapas de humedad actualizados diariamente, se podrán descargar los datos pasados para analizar tendencias y realizar estudios enfocados a mejorar la gestión del territorio.

En definitiva, este aplicativo pretende establecer la base para la conformación de un índice integral de riesgo de incendio común para toda la zona mediterránea, que reduzca los efectos de este tipo de perturbaciones y disminuya el coste que supone la movilización de recursos de extinción mediante la anticipación a su ocurrencia.

8. Referencias

- AEMET. (2018a). AEMET Open Data. Sistema para la difusión y reutilización de la información de la Agencia Estatal de Meteorología. Recuperado de <https://opendata.aemet.es/centrodedescargas/inicio>
- AEMET. (2018b). Mapa de niveles de riesgo de incendio previstos. Agencia Estatal de Meteorología. Recuperado de <http://www.aemet.es/es/eltiempo/prediccion/incendios>
- AEMET-IM. (2011). *Iberian Climate Atlas. Air Temperature and Precipitation (1971-2000)*. Agencia Estatal de Meteorología de España e Instituto Nacional de Meteorología de Portugal.
- Aguado, I., y Camia, A. (1998). Fundamentos Y Utilización De Índices Meteorológicos De Peligro De Incendio. *Serie Geográfica*, 7, 49–58.
- Aguado, I., Chuvieco, E., Borén, R., y Nieto, H. (2007). Estimation of dead fuel moisture content from meteorological data in Mediterranean areas. Applications in fire danger assessment. *International Journal of Wildland Fire*, 16(4), 390–397. <https://doi.org/10.1071/WF06136>
- Akaike, H. (1974). A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. <https://doi.org/10.1109/TAC.1974.1100705>
- Baddeley, A. (2008). Analysing spatial point patterns in R. *Technical Report, CSIRO, 2010. Version 4*, 1–199. <https://doi.org/10.1007/s00415-011-6369-2>
- Baddeley, A., y Turner, R. (2005). spatstat: An R Package for Analyzing Spatial Point Patterns. *Journal of Statistical Software*, 12(6), 1–42.
- Beek, E. G. (1991). Spatial interpolation of daily meteorological data. Theoretical evaluation of available techniques. *Report*, 53, 43.
- Benavides, R., Montes, F., Rubio, A., y Osoro, K. (2007). Geostatistical modelling of air temperature in a mountainous region of Northern Spain. *Agricultural and Forest Meteorology*, 146(3–4), 173–188. <https://doi.org/10.1016/j.agrformet.2007.05.014>
- Bivand, R., Pebesma, E., y Gómez-Rubio, V. (2013). *Applied Spatial Data Analysis with R*. Springer (Second Ed.). New York, NY: Springer New York. <https://doi.org/10.1007/978-0-387-78171-6>
- Boer, M. M., Nolan, R. H., Resco De Dios, V., Clarke, H., Price, O. F., y Bradstock, R. A. (2017). Changing Weather Extremes Call for Early Warning of Potential for Catastrophic Fire. *Earth's Future*, 5(12), 1196–1202. <https://doi.org/10.1002/2017EF000657>
- Bradstock, R. A. (2010). A biogeographic model of fire regimes in Australia: Current and future implications. *Global Ecology and Biogeography*, 19(2), 145–158. <https://doi.org/10.1111/j.1466-8238.2009.00512.x>
- Burriel, J. A., Castro, X., Mata, T., Montserrat Agudé, D., Gabriel de Francisco, E., y Ibáñez i Martí, J. (2006). La Mejora Del Mapa Diario De Riesgo De Incendio Forestal En Cataluña. En *El acceso a la información espacial y las nuevas tecnologías geográficas. XII Congreso Nacional de*

- tecnologías de la información geográfica.* (pp. 1–15).
- Cabrero Ortega, Y., y García Pérez, A. (2015). *Análisis estadístico de datos espaciales con QGIS y R*. Madrid: Universidad Nacional de Educación a Distancia UNED.
- Cáceres, M. De, Martin, N., Granda, V., y Cabon, A. (2018). Meteoland: Landscape Meteorology Tools. R package version 0.7.1.
- Castellnou, M., Miralles, M., y Molina, D. (2005). Análisis de la disponibilidad de combustible: índices meteorológicos críticos para la ocurrencia de cada patrón de grandes incendios forestales en la zona de Tivissa. *IV Congreso Forestal Español. Zaragoza*, (September 2017).
- Castellnou, M., Pagés, J., Miralles, M., y Piqué, M. (2009). Tipificación de los incendios forestales de Cataluña. Elaboración del mapa de incendios de diseño como herramienta para la gestión forestal. Ávila: 5º Congreso Forestal.
- Chuvieco, E., Aguado, I., y Dimitrakopoulos, A. P. (2004). Conversion of fuel moisture content values to ignition potential for integrated fire danger assessment. *Canadian Journal of Forest Research*, 34(11), 2284–2293. <https://doi.org/10.1139/x04-101>
- Chuvieso, E. (2003). *Wildland fire danger: estimation and mapping: the role of remote sensing data*. River Edge, N.J: World Scientific.
- Chuvieso, E., y Martín, M. del P. (2004). *Nuevas tecnologías para la estimación del riesgo de incendios forestales*. Madrid: Consejo Superior de Investigaciones Científicas.
- Cressie, N. A. C. (1993). *Statistics for Spatial Data* (Revised Ed). United States of America: Wiley-Interscience Publication.
- Daly, C., Halbleib, M., Smith, J. I., Gibson, W. P., Doggett, M. K., Taylor, G. H., ... Pasteris, P. P. (2008). Physiographically sensitive mapping of climatological temperature and precipitation across the conterminous United States. *International Journal of Climatology*, 28(December 2007), 1549–1555. <https://doi.org/10.1002/joc>
- DARPA. (2018). Mapa de predicció de perill d’incendi forestal. Recuperado de <http://www.gencat.cat/medinatural/incendis/mapaperill>
- Duursma, R. A. (2015). Plantecophys - An R Package for Analysing and Modelling Leaf Gas Exchange Data. PLoS ONE, 10(11), e0143346. <https://doi.org/http://doi.org/10.1371/journal.pone.0143346>
- European Commission. (2018). Copernicus Emergency Management Service. Recuperado de <http://effis.jrc.ec.europa.eu/>
- Gallardo, A. (2006). Geostatística. *Geostatística . Ecosistemas*, 3(1987), 1–11.
- Gaona, G., Quentin, E., y Labus, J. (2013). Homogeneidad y variabilidad espacial de series meteorológicas del área del proyecto “Ciudad del Conocimiento-Yachay.” *Avances En Ciencias E Ingenierías*, 5(2), C22–C34. <https://doi.org/10.18272/aci.v5i2.138>
- Generalitat de Catalunya. (2009). Jornades Tècniques del cos de bombers: capacitat de gestió dels incendis forestals. Girona, 18 i 19 de Novembre de 2009. Conclusions. Girona: Direcció General de Prevenció i Extinció d’Incendis i Salvament.
- Gray, M. E., Zachmann, L. J., y Dickson, B. G. (2018). A weekly, near real-time dataset of the probability of large wildfires across western US forests and woodlands. *Earth System Science Data*, 1(September), 1715–1727. <https://doi.org/10.5194/essd-10-1715-2018>

- Haberlandt, U. (2007). Geostatistical interpolation of hourly precipitation from rain gauges and radar for a large-scale extreme rainfall event. *Journal of Hydrology*, 332(1–2), 144–157. <https://doi.org/10.1016/j.jhydrol.2006.06.028>
- Hardy, C. C. (2005). Wildland fire hazard and risk: Problems, definitions, and context. *Forest Ecology and Management*, 211(1–2), 73–82. <https://doi.org/10.1016/j.foreco.2005.01.029>
- Hartkamp, a D., De Beurs, K., Stein, A., y White, J. W. (1999). Interpolation Techniques for Climate Variables Interpolation. *Soil Science*, 26.
- Hengl, T. (2006). Finding the right pixel size. *Computers and Geosciences*, 32(9), 1283–1298. <https://doi.org/10.1016/j.cageo.2005.11.008>
- Hengl, T. (2009). *A Practical guide to Geostatistical Mapping. Scientific and Technical Research series*. [https://doi.org/10.1016/0277-9390\(86\)90082-8](https://doi.org/10.1016/0277-9390(86)90082-8)
- Hernández, L. (2017). Fuego a las puertas. Cómo los incendios afectan cada vez más a la población en España. *World Wide Fund For Nature (WWF) España*.
- IGN. (2018). Instituto Geográfico Nacional. Modelo Digital de Elevaciones de España. MDT200. Recuperado de <http://centrodedescargas.cnig.es/CentroDescargas/catalogo.do?Serie=LIDAR#>
- Li, J., y Heap, A. D. (2008). A Review of Spatial Interpolation Methods for Environmental Scientists. *Australian Geological Survey Organisation*, 68(2008/23), 154. https://doi.org/http://www.ga.gov.au/image_cache/GA12526.pdf
- Li, J., y Heap, A. D. (2011). A review of comparative studies of spatial interpolation methods in environmental sciences: Performance and impact factors. *Ecological Informatics*, 6(3–4), 228–241. <https://doi.org/10.1016/j.ecoinf.2010.12.003>
- Li, J., y Heap, A. D. (2014). Spatial interpolation methods applied in the environmental sciences: A review. *Environmental Modelling and Software*, 53, 173–189. <https://doi.org/10.1016/j.envsoft.2013.12.008>
- Lu, C.-T., Chen, D., y Kou, Y. (2003). Algorithms for spatial outlier detection. *Third IEEE International Conference on Data Mining*, 0–3. <https://doi.org/10.1109/ICDM.2003.1250986>
- Martin Soler, M., Bonet, J. A., Martínez De Aragón, J., Voltas, J., Coll, L., y Resco De Dios, V. (2017). Crown bulk density and fuelmoisture dynamics in Pinus pinaster stands are neither modified by thinning nor captured by the Forest FireWeather Index. *Annals of Forest Science*. <https://doi.org/10.1007/s12192-010-0223-9>
- Matthews, S. (2013). Dead fuel moisture research: 1991 – 2012. *International Journal of Wildland Fire*, 23, 78–92. <https://doi.org/10.1071/WF13005>
- Miller, H. J. (2004). Tobler ’ s First Law and Spatial Analysis. *Annals of the Association of American Geographers*, 94(2), 284–289. <https://doi.org/10.1111/j.1467-8306.2004.09402005.x>
- Miranda-Salas, M., y Condal, A. R. (2003). Importancia del análisis estadístico exploratorio en el proceso de interpolación espacial: caso de estudio Reserva Forestal Valdivia. *Bosque (Valdivia)*, 24(2), 29–42. <https://doi.org/https://dx.doi.org/10.4067/S0717-92002003000200004>
- Monteith, J., y Unsworth, M. (2013). *Principles of Environmental Physics: Plants, Animals, and the Atmosphere*. Academic Press. Fourth Edition. <https://doi.org/10.1016/C2010-0-66393-0>
- Nelson, R. M. (2001). Water Relations of Forest Fuels. En E. E. A. Johnson and K. Miyanishi (Ed.),

- Forest fires: behavior and ecological effects* (pp. 79–149). San Diego, California: Academic Press.
- Nolan, R. H., Boer, M. M., Resco De Dios, V., Caccamo, G., y Bradstock, R. A. (2016). Large-scale, dynamic transformations in fuel moisture drive wildfire activity across southeastern Australia. *Geophysical Research Letters*, *43*(9), 4229–4238. <https://doi.org/10.1002/2016GL068614>
- Nolan, R. H., Resco de Dios, V., Boer, M. M., Caccamo, G., Goulden, M. L., y Bradstock, R. A. (2016). Predicting dead fine fuel moisture at regional scales using vapour pressure deficit from MODIS and gridded weather data. *Remote Sensing of Environment*, *174*, 100–108. <https://doi.org/10.1016/j.rse.2015.12.010>
- NSW Rural Fire Service. (2018). New South Wales Rural Fire Service. Fire Danger Ratings. Recuperado de <https://www.rfs.nsw.gov.au/>
- Olaya, V. (2014). Sistemas de Información Geográfica. *Journal of Chemical Information and Modeling*, *53*(9), 1689–1699. <https://doi.org/10.1017/CBO9781107415324.004>
- Olson, D. M., Dinerstein, E., Wikramanayake, E. D., Burgess, N. D., Powell, G. V. N., Underwood, E. C., ... Kassem, K. R. (2001). Terrestrial Ecoregions of the World: A New Map of Life on Earth. *BioScience*, *51*(11), 933. [https://doi.org/10.1641/0006-3568\(2001\)051\[0933:TEOTWA\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2001)051[0933:TEOTWA]2.0.CO;2)
- Pausas, J. G. (2004). Changes in fire and climate in the eastern Iberian Peninsula (Mediterranean Basin). *Climatic Change*, *63*(3), 337–350. <https://doi.org/10.1023/B:CLIM.0000018508.94901.9c>
- Pausas, J. G., y Fernández-Muñoz, S. (2012). Fire regime changes in the Western Mediterranean Basin: from fuel-limited to drought-driven fire regime. *Climatic Change*, *110*(1–2), 215–226.
- Pausas, J. G., y Vallejo, R. (2008). Bases ecológicas para convivir con los incendios forestales en la Región Mediterránea: decálogo. *Ecosistemas*, *17*(2), 128–129.
- Pebesma, E. J. (2004). Multivariable geostatistics in S: The gstat package. *Computers and Geosciences*, *30*(7), 683–691. <https://doi.org/10.1016/j.cageo.2004.03.012>
- Pebesma, E. J., y Bivand, R. (2005). Classes and methods for spatial data in R. *R News* *5* (2).
- R Core Team. (2018). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Resco de Dios, V., Fellows, A. W., Nolan, R. H., Boer, M. M., Bradstock, R. A., Domingo, F., y Goulden, M. L. (2015). A semi-mechanistic model for predicting the moisture content of fine litter. *Agricultural and Forest Meteorology*, *203*, 64–73. <https://doi.org/10.1016/j.agrformet.2015.01.002>
- Rossiter, D. G. (2017). An introduction to geostatistics with R/gstat, 1–81.
- Rothermel, R. C. (1972). A mathematical model for predicting fire spread in wildland fuels. *USDA Forest Service Research Paper INT USA*, (INT-115), 40.
- Ruiz González, A., y Vega Hidalgo, J. A. (2007). *Modelos de predicción de la humedad de los combustibles muertos: fundamentos y aplicación*. Madrid: Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria.
- Sánchez-Palomares, O., Sánchez-Serrano, F., y Carretero, M. P. (1999). *Modelos y Cartografía de estimaciones climáticas termopluviométricas para la España peninsular*. Madrid: Ministerio de Agricultura, Pesca y Alimentación. Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria. <https://doi.org/10.1007/s11295-016-1022-y>

- Scott, A. C., Bowman, D. M. J. S., Bond, W. J., Pyne, S. J., y Alexander, M. E. (2014). *Fire on Earth: an introduction*. John Wiley-Blackwell.
- Stahl, K., Moore, R. D., Floyer, J. A., Asplin, M. G., y McKendry, I. G. (2006). Comparison of approaches for spatial interpolation of daily air temperature in a large region with complex topography and highly variable station density. *Agricultural and Forest Meteorology*, 139(3–4), 224–236. <https://doi.org/10.1016/j.agrformet.2006.07.004>
- Vélez, R. (1995). El peligro de incendios forestales derivado de la sequía. *Cuadernos de La Sociedad Española de Ciencias Forestales*, (2), 11.
- Wallace, J., y Hobbs, P. (2006). *Atmospheric science: an introductory survey. (Vol. 92)*. Elsevier. (Vol. 92). Elsevier. <https://doi.org/10.1017/CBO9781107415324.004>
- Webster, R., y Oliver, M. A. (2007). *Geostatistics for Environmental Scientists. Statistics in Practise* (2nd ed., Vol. 1). Chichester: John Wiley y Sons. <https://doi.org/10.2136/vzj2002.0321>
- Wu, J., Norvell, W. A., y Welch, R. M. (2006). Kriging on highly skewed data for DTPA-extractable soil Zn with auxiliary information for pH and organic carbon. *Geoderma*, 134(1–2), 187–199. <https://doi.org/10.1016/j.geoderma.2005.11.002>
- Wu, T., y Li, Y. (2013). Spatial interpolation of temperature in the United States using residual kriging. *Applied Geography*, 44, 112–120. <https://doi.org/10.1016/j.apgeog.2013.07.012>